

**Universidad Politécnica de Cartagena**

Departamento de Ingeniería de Sistemas y Automática



---

**Sistemas de Interfaz Cerebro-Ordenador  
Basados en Dispositivos EEG de Bajo Coste  
y Modelos Neurodifusos Aplicados a la  
Imaginación de Movimiento**

---

Tesis Doctoral

Juan Antonio Martínez León

Directores

José Manuel Cano Izquierdo

Julio José Ibarrola Lacalle

**2018**



**CONFORMIDAD DE SOLICITUD DE AUTORIZACIÓN DE DEPÓSITO DE  
TESIS DOCTORAL POR EL/LA DIRECTOR/A DE LA TESIS**

D./D<sup>a</sup>. José Manuel Cano Izquierdo Director/a de la Tesis  
doctoral Sistemas de Interfaz Cerebro-Ordenador Basados en Dispositivos EEG de Bajo  
Coste y Modelos Neurodifusos Aplicados a la Imaginación de Movimiento

**INFORMA:**

Que la referida Tesis Doctoral, ha sido realizada por D/D<sup>a</sup>. Juan Antonio Martínez León  
-----, dentro del programa de doctorado Tecnologías Industriales  
-----, dando mi conformidad para que sea presentada  
ante la Comisión de Doctorado para ser autorizado su depósito.

La rama de conocimiento en la que esta tesis ha sido desarrollada es:

- Ciencias  
Ciencias Sociales y Jurídicas  
☒ Ingeniería y Arquitectura

En Cartagena, a 14 de Noviembre de 2018

EL/LA DIRECTOR/A DE LA TESIS

Fdo.: José Manuel Cano Izquierdo

**COMISIÓN DE DOCTORADO**



**CONFORMIDAD DE SOLICITUD DE AUTORIZACIÓN DE DEPÓSITO DE  
TESIS DOCTORAL POR EL/LA DIRECTOR/A DE LA TESIS**

D./D<sup>a</sup>. Julio José Ibarrola Lacalle Director/a de la Tesis  
doctoral Sistemas de Interfaz Cerebro-Ordenador Basados en Dispositivos EEG de Bajo  
Coste y Modelos Neurodifusos Aplicados a la Imaginación de Movimiento

**INFORMA:**


Que la referida Tesis Doctoral, ha sido realizada por D/D<sup>a</sup>. Juan Antonio Martínez León  
Tecnologías Industriales, dentro del programa de doctorado Tecnologías Industriales, dando mi conformidad para que sea presentada ante la Comisión de Doctorado para ser autorizado su depósito.

La rama de conocimiento en la que esta tesis ha sido desarrollada es:

- ☐ Ciencias
- ☐ Ciencias Sociales y Jurídicas
- ☒ Ingeniería y Arquitectura

En Cartagena, a 14 de Noviembre de 2018

EL/LA CODIRECTOR/A DE LA TESIS



Fdo.: Julio José Ibarrola Lacalle

**COMISIÓN DE DOCTORADO**



**CONFORMIDAD DE DEPÓSITO DE TESIS DOCTORAL  
POR LA COMISIÓN ACADÉMICA DEL PROGRAMA**

D/D<sup>a</sup>. Juan Suardíaz Muro Presidente/a de la  
Comisión Académica del Programa en Tecnologías Industriales.

**INFORMA:**

Que la Tesis Doctoral titulada, “Sistemas de Interfaz Cerebro-Ordenador Basados en Dispositivos EEG de Bajo Coste y Modelos Neurodifusos Aplicados a la Imaginación de Movimiento”.

-----”, ha sido realizada, dentro del mencionado programa de doctorado,  
por D/D<sup>a</sup>. Juan Antonio Martínez Leon,

bajo la dirección y supervisión del Dr/ Dra. José Manuel Cano Izquierdo.

En reunión de la Comisión Académica de fecha 14/11/2018 , visto que en la misma se acreditan los indicios de calidad correspondientes y la autorización del Director de la misma, se acordó dar la conformidad, con la finalidad de que sea autorizado su depósito por la Comisión de Doctorado.

La Rama de conocimiento por la que esta tesis ha sido desarrollada es:

- ☐ Ciencias
- ☐ Ciencias Sociales y Jurídicas
- ☒ Ingeniería y Arquitectura

En Cartagena, a 19 de Noviembre de 2018

EL PRESIDENTE DE LA COMISIÓN ACADÉMICA DEL PROGRAMA

Fdo: Juan Suardíaz Muro

**COMISIÓN DE DOCTORADO**



# Agradecimientos

Esta tesis doctoral no podría empezar de otra forma que expresando mi gratitud a todas aquellas personas que me han acompañado durante este viaje.

En primer lugar, quisiera darles las gracias a mis directores, los doctores José Manuel Cano y Julio Ibarrola por haberme ayudado y guiado en la consecución de esta tesis doctoral. He tenido la suerte de colaborar con dos grandes profesionales y más aún personas, que me han aportado tanto orientación académica como amor por la ciencia. Si no hubiese sido por vuestra flexibilidad y voluntad de ir siempre más allá estas palabras jamás se hubiesen escrito. Más que directores, tengo la suerte de tener dos amigos que han luchado a mi lado para que este trabajo salga adelante.

Tampoco hubiera podido ser posible este documento sin la colaboración de los amigos y familiares que voluntaria y desinteresadamente me han prestado su tiempo y su cerebro. Me habéis permitido tener los mimbres necesarios para realizar este trabajo y aportado el empuje necesario para cerrar esta etapa. Gracias por vuestros ánimos, vuestras preguntas y sobre todo, vuestra compañía.

Quiero agradecer al personal de la UPCT su ayuda durante este camino, en especial a Pablo Martínez en el apartado técnico y a Trini Galera y Marisa Rubio en los no siempre fáciles procesos administrativos.

También quisiera reconocer la contribución de los profesores de la ETSIT Pablo Pavón Mariño, que no me dejó desviarme del camino investigador, y de Alejandro Martínez Sala y Joan García Haró, gracias a quienes empecé los cursos de doctorado.

Ninguna de estas líneas existiría sin el apoyo incondicional de mi familia, que ha sabido tanto comprenderme como retarme cuando ha sido necesario. Gracias por los esfuerzos realizados para que me permitieron estudiar y forjarme libremente mi camino. Gracias por haberme inculcado el carácter, el coraje y la determinación para conseguir mis metas. Gracias por hacerme una persona feliz.



# Resumen

La presente tesis doctoral detalla la evaluación de un dispositivo de electroencefalografía de bajo coste a partir de su inclusión en un sistema de interfaz cerebro-máquina completo (BCI del inglés Brain-Computer Interfaces) basado en técnicas neurodifusas. El paradigma elegido se centra en la imaginación de movimiento multiclase sin realimentación, donde la operación es completamente asíncrona. También se ha aportado un avance en el área de la selección de características, desarrollando e implementando una metodología capaz de minimizar las componentes del vector de características necesarias para operar sistemas BCI, facilitando así la integración de éstos en plataformas móviles.

En primer lugar, se ha seleccionado el dispositivo Emotiv EPOC en torno a criterios de coste, número de sensores, acceso a la señal capturada, ergonomía y relevancia para la comunidad científica. Del mismo modo, se ha abordado el problema definido en el BCI Competition III dataset V dada la disponibilidad de las señales capturadas sobre el cuero cabelludo por un equipo profesional, la exhaustiva definición del experimento y la facilidad para reproducirlo. Adicionalmente, la existencia de estudios utilizando estos mismos datos ha ofrecido una guía sobre las mejores técnicas a aplicar. Entre éstas destaca el modelo neurodifuso S-dFasArt, que hasta ahora ha presentado los mejores resultados cumpliendo las restricciones del problema. Por tanto, se ha construido un sistema BCI propio utilizando Emotiv EPOC como dispositivo de obtención de la señal EEG y S-dFasArt como sistema de inteligencia artificial.

La valoración se ha realizado desde el punto de vista de un sistema BCI completo por lo que, en lugar de examinar la forma de la señal detectada, se ha calculado el rendimiento del mismo para datos capturados con diferentes equipos. Para ello se han comparado los resultados alcanzados tanto a partir de la base de datos BCI Competition como de cuatro conjuntos propios en los que han colaborado 19 voluntarios, quienes han participado en uno o varios experimentos. Se han incluido tanto sesiones utilizando Emotiv EPOC para la obtención de datos, como pruebas donde se ha utilizado una versión híbrida del mismo, en la cual se mantiene la unidad de procesamiento pero varía la tecnología y la ubicación de los sensores.

Así, se ha demostrado que el sistema BCI construido integrando Emotiv EPOC junto al clasificador S-dFasArt alcanza una precisión asimilable a la lograda sobre datos capturados por equipos de investigación manteniendo el problema y la posición de los sensores. Además, la ubicación de los mismos sobre la corteza motora ha hecho posible un incremento en torno al 7 % en el nivel de acierto medio (desde el 62 % al 66.53 %). Igualmente, se ha corroborado la influencia positiva de la realimentación, que ha permitido lograr precisiones

de por encima del 70 % con Emotiv EPOC.

Finamente, se ha presentado una metodología de selección de características en la que el S-dFasArt se ha integrado con modelos basados en combinaciones entre el método estadístico y el criterio difuso con la selección por orden y GMDH. La metodología desarrollada ha seleccionado automáticamente las componentes más relevantes del vector de características, alcanzando el modelo reducido obtenido por las diferentes variantes mejores resultados que el completo para dos de cada tres sujetos. Igualmente, la disminución del tamaño del conjunto de datos es muy significativa, presentando un decremento medio desde 168 a 5 características para la mejor combinación.

# Abstract

This PhD thesis details the evaluation process of a low-cost electroencephalography device when included into a brain-computer interface system (BCI) based on neuro-fuzzy techniques. The chosen paradigm focuses on the multi-class motor imagery problem, with no feedback and asynchronous operation. Also, a contribution to the feature selection area is presented, developing and implementing a new methodology able to minimise the number of feature vector components required to operate BCI systems, thus facilitating their integration into mobile platforms.

First, the Emotiv EPOC EEG device has been selected after performing an economic evaluation considering cost and aspects such as the number of sensors, the available capabilities to access the raw brain data, the ergonomics and the relevance for the scientific community. Likewise, the BCI Competition III Dataset V defined problem has been undertaken. This has been chosen based on the availability of the raw brain signals, the detailed description of the experiment and the ability to reproduce it. Also, the existence of a number of research papers has provided guidance about the best performing approaches tackling this problem. Among them, the S-dFasArt neuro-fuzzy model has shown the best performance following the experiment rules so far. Therefore, a new BCI system has been built using Emotiv EPOC as a data capture device and S-dFasArt as an artificial intelligence unit.

This assessment has been performed from the perspective of a complete BCI system so, instead of examining the shape of the detected brainwave, the performance of the setup using different data gathering devices has been analysed. Given that, a comparison of the results obtained has been performed processing data from several databases, including the BCI Competition and other four purposely-built datasets containing brain signals recorded from 19 volunteers participating in one or more experiments. Datasets include scalp potentials recorded using Emotiv EPOC as well as sessions recorded by a hybrid version of it, which maintains the processing unit while integrating a different sensor technology and allowing the setup at different electrode locations.

Thus, the BCI system built integrating Emotiv EPOC and the S-dFasArt classifier has shown an accuracy level comparable to that achieved using research EEG devices for the same problem and sensor locations. Besides, placing the electrodes over the motor cortex has allowed a 7% increase of the average success rate (from 62% to 66.53%). Additionally, the importance of providing users with live feedback of their performance has been corroborated, obtaining accuracy levels above 70% using Emotiv EPOC.

Finally, a new methodology where S-dFasArt is integrated with a combination of eit-

her the statistic method or the fuzzy criteria and the order selection or GMDH has been introduced. The developed methodology has automatically selected the most relevant components from the feature vector, allowing the reduced model calculated from the different variations to achieve better than original accuracy levels for two out of three subjects. Moreover, a very significant average reduction from 168 to 5 features has been achieved for the highest performing combination.



# Índice general

<b>1. Objetivos</b>	<b>15</b>
1.1. Introducción . . . . .	15
1.2. Objetivos . . . . .	16
1.3. Estructura y metodología . . . . .	17
<b>2. Antecedentes</b>	<b>19</b>
2.1. El Sistema Nervioso . . . . .	19
2.2. El Cerebro . . . . .	21
2.2.1. Estructura y Funciones Cerebrales . . . . .	21
2.3. La Médula Espinal . . . . .	22
2.3.1. Estructura y Funciones de la Médula Espinal . . . . .	22
2.4. Interfaces Cerebro Máquina . . . . .	23
2.4.1. Procedimientos de Medida de la Actividad Cerebral . . . . .	24
2.4.2. Componentes de un sistema EEG . . . . .	28
2.4.3. Señales detectadas por los sistemas BCI basados en EEG . . . . .	30
2.4.4. Protocolo de comunicaciones . . . . .	32
2.5. Equipos de Captura de Datos EEG Profesionales . . . . .	32
2.6. Equipos de Captura de Datos EEG de Bajo Coste . . . . .	36
2.6.1. Emotiv EPOC . . . . .	40
2.6.2. Emotiv EPOC - EasyCap . . . . .	56
2.7. Datos BCI Competition . . . . .	58
2.7.1. Potenciales cerebrales . . . . .	59
2.7.2. Datos preprocesados . . . . .	60
2.8. Preprocesamiento . . . . .	60
2.9. Clasificación . . . . .	62
2.9.1. Algoritmos neuro difusos - Modelos ART . . . . .	64
2.9.2. Supervised and dynamic Fuzzy Adaptative System ART-base (S- dFasArt) . . . . .	67
2.10. Algoritmos de Selección de Características . . . . .	70
<b>3. Evaluación del sistema EEG Emotiv EPOC</b>	<b>75</b>
3.1. Captura de Datos . . . . .	76
3.1.1. Conjuntos de datos . . . . .	76

3.1.2.	Experimento y participantes . . . . .	77
3.2.	Metodología de preprocesamiento . . . . .	82
3.3.	Clasificación . . . . .	84
3.3.1.	Parámetros de clasificación . . . . .	85
3.4.	Resultados . . . . .	87
3.4.1.	Datos preprocesados BCI Competition III dataset V . . . . .	88
3.4.2.	Datos BCI Competition III dataset V - Posiciones Emotiv . . . . .	89
3.4.3.	Datos capturados con Emotiv EPOC . . . . .	90
3.4.4.	Datos capturados con Emotiv EasyCap - Posiciones BCI Competition . . . . .	92
3.4.5.	Datos capturados con Emotiv EasyCap - Posiciones Emotiv . . . . .	93
3.4.6.	Datos capturados con Emotiv EPOC - Base de datos extendida . . . . .	95
3.4.7.	Efecto de la velocidad de reset $A_r$ en el acierto de clasificación . . . . .	99
3.4.8.	Efecto del cálculo de la PSD en el acierto de clasificación . . . . .	100
3.4.9.	Efecto de la realimentación en el acierto de clasificación . . . . .	102
3.5.	Conclusiones . . . . .	103
3.5.1.	Comparación datos BCI Competition III dataset V . . . . .	104
3.5.2.	Comparación datos EasyEpoC . . . . .	106
3.5.3.	Comparación datos BCI Competition III Set V y Emotiv EasyCap - Posiciones BCI . . . . .	108
3.5.4.	Comparación datos BCI Competition III Set V y Emotiv EasyCap - Posiciones Emotiv . . . . .	111
3.5.5.	Comparación de datos disponibles para posiciones Emotiv EPOC . . . . .	113
3.5.6.	Generalización de los resultados Emotiv EPOC base de datos exten- dida . . . . .	118
3.5.7.	Análisis General . . . . .	119
<b>4.</b>	<b>Selección de Características</b>	<b>123</b>
4.1.	Metodología . . . . .	124
4.1.1.	Carácter discriminante de las características . . . . .	125
4.1.2.	Puntuación, ordenación y selección . . . . .	126
4.1.3.	Selección de características . . . . .	128
4.2.	Resultados . . . . .	129
4.2.1.	Datos preprocesados BCI Competition III dataset V . . . . .	129
4.2.2.	Datos BCI Competition III dataset V - Posiciones Emotiv . . . . .	141
4.2.3.	Datos capturados con Emotiv EPOC . . . . .	145
4.2.4.	Datos capturados con Emotiv EasyCap - Posiciones BCI Competition . . . . .	149
4.2.5.	Datos capturados con Emotiv EasyCap - Posiciones Emotiv . . . . .	153
4.2.6.	Datos capturados con Emotiv EPOC - Base de datos extendida . . . . .	157
4.3.	Interpretabilidad de los resultados . . . . .	166
4.3.1.	Modelo Unificado . . . . .	166
4.3.2.	Reglas difusas . . . . .	168
4.4.	Conclusiones . . . . .	170
4.4.1.	Bondad de metodología . . . . .	170
4.4.2.	Características de los resultados . . . . .	171

4.4.3. Mejora en el tiempo de procesado . . . . .	175
<b>5. Conclusiones y Líneas Futuras</b>	<b>177</b>
5.1. Conclusiones . . . . .	177
5.2. Líneas futuras . . . . .	178
<b>Bibliografía</b>	<b>180</b>
<b>A. Cuestionario posterior a la toma de datos</b>	<b>221</b>
A.1. Preguntas incluidas . . . . .	221
<b>B. Resultados S-dFasArt - Base de Datos BCIComp</b>	<b>223</b>
<b>C. Resultados S-dFasArt - Base de Datos BCIEpoc</b>	<b>227</b>
<b>D. Resultados S-dFasArt - Base de Datos EmoEpoc</b>	<b>231</b>
<b>E. Resultados S-dFasArt - Base de Datos EasyBCI</b>	<b>235</b>
<b>F. Resultados S-dFasArt - Base de Datos EasyEpoc</b>	<b>239</b>
<b>G. Resultados S-dFasArt - Base de Datos EmoExt</b>	<b>243</b>
<b>H. Resultados S-dFasArt - Base de Datos EmoExt - Comparativa PSD</b>	<b>257</b>
<b>I. Resultados S-dFasArt - Realimentación</b>	<b>283</b>
<b>J. Resultados Selección de Características. Base de Datos BCIComp</b>	<b>289</b>
<b>K. Resultados Selección de Características. Base de Datos BCIEpoc</b>	<b>293</b>
<b>L. Resultados Selección de Características. Base de Datos EmoEpoc</b>	<b>297</b>
<b>M. Resultados Selección de Características. Base de Datos EasyBCI</b>	<b>301</b>
<b>N. Resultados Selección de Características. Base de Datos EasyEpoc</b>	<b>305</b>
<b>Ñ. Resultados Selección de Características. Base de Datos EmoExt</b>	<b>309</b>
<b>O. Resultados Selección de Características. Modelo Común</b>	<b>323</b>
<b>Publicaciones</b>	<b>323</b>



# Capítulo 1

## Objetivos

### 1.1. Introducción

Una de las claves de la existencia humana está en su habilidad para comunicarse e interactuar con el entorno. Estos procesos se dan no sólo entre individuos sino también con aparatos y dispositivos de uso diario. Por tanto, el deterioro o la pérdida de la capacidad de relación experimentada como resultado de accidentes cerebrovasculares o lesiones en la médula espinal no sólo tiene una connotación física, sino que provocan un fuerte trauma psicológico.

Cuando se revisan las estadísticas acerca del impacto de estas dos patologías se observa que, de acuerdo a la Organización Mundial de la Salud, 15 millones de personas sufren accidentes cerebrovasculares cada año, quedando alrededor de la mitad de ellos con algún grado de discapacidad física o cognitiva [1, 2]. Además, estos casos se producen mayoritariamente en personas de edad avanzada y en el 87%, en países con rentas per cápita medias y bajas.

Los datos relacionados con las lesiones de médula espinal no son más alentadores. Anualmente, entre 250.000 y 500.000 personas sufren daños de este tipo, fundamentalmente causados por accidentes de tráfico o caídas. Demográficamente, las poblaciones de más riesgo están entre los 15 y los 29 años y a partir de los 60, cuya esperanza de vida disminuye en países con rentas medias y bajas debido a la mayor incidencia de otras enfermedades [3].

Por tanto, existe una población mundial, que crece a un ritmo de ocho millones de personas anualmente, cuyas facultades para comunicarse con su entorno quedan mermadas en distinto grado para el resto de su existencia. La industria y la tecnología no son ajenas a ellos, ni a un mercado en tecnologías asistenciales que se prevé que sobrepase los \$26 mil millones en 2024 [4]. Dentro de éste, los Interfaces Cerebro Máquina (BCI del inglés Brain Computer Interface), que posibilitan la operación de dispositivos externos a partir de la detección e interpretación de las intenciones de los sujetos utilizando sus ondas cerebrales, son una de las áreas de mayor atención, fundamentalmente por sus posibilidades en conjunción con prótesis rehabilitadoras.

Entre las tecnologías en la captura de la señal cerebral integradas en sistemas BCI

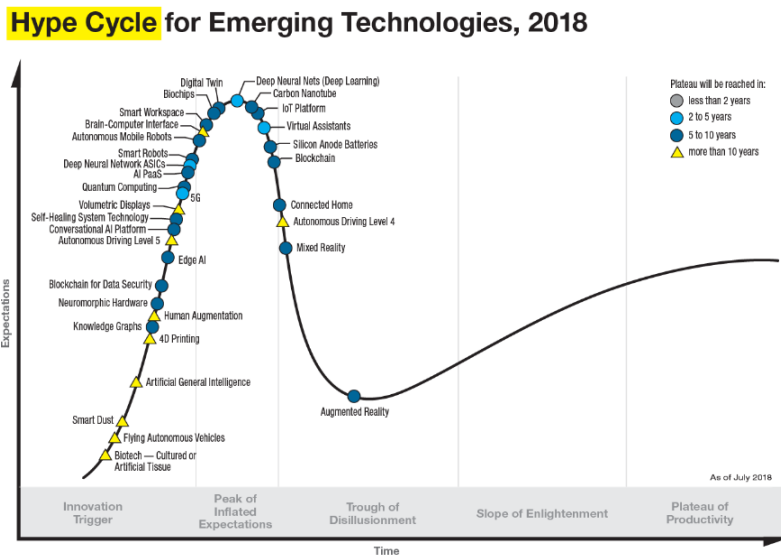


Figura 1.1: Representación gráfica del ciclo de vida de los avances tecnológicos desde su concepción hasta su adopción masiva [5]

destacan los equipos de electroencefalografía (EEG). Éstos se basan en la colocación de una serie de electrodos sobre el cuero cabelludo del usuario que pueden detectar las fluctuaciones de voltaje resultantes de las corrientes iónicas existentes en las neuronas. El coste de estos dispositivos ha estado tradicionalmente en el rango de las decenas de miles de euros, dificultando el acceso a los mismos a los propios investigadores.

Como se muestra en la Figura 1.1, aunque de acuerdo con Gartner la adopción masiva de los sistemas BCI no llegará al menos en 10 años [5], sí que se están realizando avances importantes que pueden acortar los plazos estimados en la aceptación de los mismos, al menos en ciertas aplicaciones. De hecho, la facilidad en el uso, la robustez, el factor de forma, la operación bajo demanda o la seguridad del portador del equipo son requisitos que han sido discutidos y compartidos por la comunidad científica durante más de una década ([6, 7]). Sin embargo, la capacidad de fabricar equipos que pudieran capturar la señal con una mínima calidad a un coste razonable ha sido hasta hace poco tiempo un impedimento importante en la adopción de la tecnología, tanto en su llegada a los hogares como a los laboratorios.

## 1.2. Objetivos

Hoy día existen en el mercado versiones simplificadas y de bajo coste de equipos de captura de datos EEG que están acercando la tecnología, en un primer término, a los investigadores e ingenieros, lo que está haciendo posible el diseño y el prototipado de dispositivos asistenciales para el público en general. Teniendo en cuenta lo expuesto anteriormente, se presenta como objetivo de este trabajo el estudio y evaluación de los sistemas



de captura de datos EEG de bajo coste desde la perspectiva de su aplicación en sistemas BCI. Este objetivo se desglosa de la siguiente forma:

1. Se analizará el mercado de los sistemas de captura de datos EEG de bajo coste, comparando sus características básicas con aquéllas disponibles en equipos de investigación y médicos, y se seleccionará un dispositivo de menos de mil dólares relevante para el ámbito científico.
2. Una vez disponible el mismo, se realizará un estudio de la calidad de los datos capturados comparándolos con los obtenidos utilizando equipos de investigación o médicos desde la perspectiva de un sistema BCI completo. Por tanto, se confeccionarán una serie de bases de datos a partir de sesiones tomadas de diferentes usuarios y se medirá la precisión alcanzada en la detección de sus pensamientos utilizando un sistema de inteligencia artificial neurodifuso de tipo S-dFasArt.
3. La adecuación de las características del dispositivo seleccionado a sistemas BCI basados en el paradigma de imaginación de movimiento será evaluada.
4. Se desarrollará una metodología de selección de características tomando como base la integración entre el sistema S-dFasArt y la combinación entre el método estadístico y el criterio difuso con la selección por orden y GMDH.
5. Finalmente, se determinará el comportamiento del conjunto de características seleccionadas para cada base de datos disponible y se discutirá la viabilidad de crear sistemas genéricos a partir de características comunes a más de un usuario.

### 1.3. Estructura y metodología

El presente trabajo se organiza de la siguiente forma:

1. En primer lugar se abordará la descripción la estructura cerebral y la diversidad en los equipos de captura de datos utilizados en los sistemas BCI. Asimismo, se realizará una revisión exhaustiva de las características del dispositivo EEG de bajo coste Emotiv EPOC y se revisará la literatura más relevante publicada utilizando el mismo. Después se presentará el BCI Competition III dataset V como base de datos de referencia. A partir de ahí se incluirán las técnicas de preprocesado, clasificación y selección de características más relevantes para las que se han publicado resultados utilizando los datos BCI Competition, prestando un detalle especial a las arquitecturas neurodifusas y al S-dFasArt.
2. El tercer capítulo está dedicado a la evaluación de la precisión del dispositivo Emotiv EPOC. En primer lugar se detallará el procedimiento de obtención de datos y la organización de los mismos, que suman en total 21 capturas útiles. Igualmente se expondrán las características de la muestra, así como una visión general sobre la percepción de los usuarios sobre el experimento. Se presentarán los resultados obtenidos aplicando S-dFasArt sobre todos los conjuntos de datos, incluidos los provenientes del

repositorio BCI Competition, detallando tanto las tasas de acierto alcanzadas por tarea como las matrices de confusión para cada usuario. Finalmente, se compararán los niveles de rendimiento alcanzados atendiendo a la ubicación de los sensores y se presentarán una serie de conclusiones.

3. En el cuarto capítulo se introducirá la metodología de selección de características propuesta, que se basa en la combinación del método estadístico y el criterio difuso con la selección por orden y GMDH, integrados conjuntamente con el clasificador S-dFasArt. De este modo surgirán cuatro opciones en la búsqueda del subconjunto de componentes más representativo. Se detallará para los datos BCI Competition III dataset V el procedimiento seguido en la obtención de las características más relevantes con el propósito de facilitar su comprensión. Para el resto se mostrarán las componentes seleccionadas por cada variante, la distribución frecuencial de las mismas y los niveles de precisión alcanzados tanto globalmente como por tarea. Después se realizará una generalización de los resultados y se propondrá un modelo común en el que se tomarán características que aparezcan para más de un usuario. Finalmente se construirá un modelo unificado a partir del cual se expondrá de un modo visual el funcionamiento de las reglas difusas en la elección de una clase u otra y se presentarán las conclusiones del capítulo.
4. El quinto capítulo está dedicado a las conclusiones finales de esta tesis doctoral. En él se utilizará la experiencia en el uso de Emotiv EPOC para evaluar el sistema BCI propuesto desde la perspectiva de la posible implementación del mismo en un sistema real. Para concluir, se incluirán sugerencias y líneas futuras a partir de las limitaciones identificadas.

## Capítulo 2

# Antecedentes

En este apartado se incluye una introducción a los conceptos más relevantes sobre los que se cimienta esta tesis doctoral. En el mismo se pueden distinguir dos grandes áreas. La primera define los fundamentos sobre los que se basa el uso de las señales cerebrales como instrumento de control. Por tanto, se incluye una breve descripción de los componentes del sistema nervioso y de los procedimientos de medida de la actividad cerebral.

La segunda se centra en los equipos de captura de datos cerebrales, especialmente en aquellos de bajo coste, y en los paradigmas clásicos de estudio dentro del campo de los interfaces cerebro-máquina (BCI del inglés Brain Computer Interface).

Por último, se añade una breve revisión de las herramientas matemáticas más comunes aplicadas a los datos capturados, como son las relacionadas con las etapas de preprocesamiento o clasificación. Del mismo modo, también se ha incluido una revisión de los algoritmos de selección de características más relevantes para el problema concreto abordado en esta tesis doctoral.

### 2.1. El Sistema Nervioso

El Sistema Nervioso gobierna la respuesta del cuerpo humano a estímulos internos y externos, permitiendo a los seres vivos relacionarse con su entorno. Se compone del Sistema Nervioso Central (SNC) y del Sistema Nervioso Periférico (SNP).

El Sistema Nervioso Central se compone del encéfalo y médula espinal, tal y como se detalla en la Figura 2.1. Ambos elementos se encuentran protegidos por elementos óseos, como son el cráneo y la columna vertebral respectivamente ([9]). Respecto a su función y estructura:

1. El encéfalo realiza el análisis de los datos recibidos y genera la respuesta pertinente a los mismos. Fisiológicamente es la parte más voluminosa del SNC, pesando en torno a los 1,5 kg ([10]) y flota en líquido cefalorraquídeo, que absorbe los impactos provocados por los movimientos de la cabeza. En cuanto a su estructura, se divide fundamentalmente en tres partes más voluminosas: cerebro, cerebelo y bulbo raquídeo, y otras más pequeñas como el diencefalo (tálamo e hipotálamo) y el me-




Figura 2.1: Estructura del Sistema Nervioso Central [8]

sencéfalo. Se encuentra recubierto por las meninges, que actúan como elementos de protección.

2. La función fundamental de la médula espinal es transferir los estímulos desde el SNP hasta el cerebro y las respuestas en sentido contrario. Dentro de la médula espinal se puede encontrar materia gris y blanca. La materia gris central se compone de células neuronales completas, mientras que la blanca la forman los axones de otras neuronas en su camino hasta las pertinentes terminaciones nerviosas.

El Sistema Nervioso Periférico está formado por nervios y terminaciones nerviosas que actúan como elementos de captura de información. Se distinguen dos tipos básicos de terminaciones nerviosas: exteroceptivas y propioceptivas. Las terminaciones nerviosas exteroceptivas se localizan superficialmente, como aquellas en la piel, y permiten capturar el tacto, el dolor o la temperatura. Por su parte, las propioceptivas se encuentran en músculos, tendones y articulaciones y proveen ajustes reflejos de la acción muscular para la posición y el movimiento.

Así, estímulos de diferente naturaleza se transforman en potenciales de acción en las terminaciones nerviosas, que se transmiten al SNC. A diferencia de éste, el SNP carece de protección ósea, por lo que es ciertamente vulnerable a daños químicos y mecánicos. En cuanto a su función, se pueden distinguir ([11]):

1. Sistema nervioso somático. Gestiona las acciones sensoriales y motoras ante estímulos externos, capturados mayoritariamente por terminaciones nerviosas exteroceptivas.
2. Sistema nervioso asomático o autónomo. Realiza tareas relacionadas con las funciones corporales internas, basadas fundamentalmente en estímulos generados por terminaciones nerviosas propioceptivas.

## 2.2. El Cerebro

### 2.2.1. Estructura y Funciones Cerebrales

El cerebro representa el 85 % del peso del encéfalo (Figura 2.2), y es el destino final de la información que se transmite a través de la médula espinal desde los sentidos. Sus lóbulos los encargados de gestionar nuestra memoria, inteligencia y sentimientos. Además, controla el resto de centros nerviosos y produce las respuestas conscientes ante los estímulos recibidos desde el SNP.

El cerebro está compuesto, en términos generales, de dos partes: la corteza cerebral, de alrededor de 3 milímetros de grosor donde existe una concentración mayor de neuronas ([12]), y las regiones subcorticales. Las regiones subcorticales se asocian con funciones básicas vitales de control como la respiración, la frecuencia cardíaca, los reflejos, el aprendizaje y la memoria. La corteza cerebral, de mayor tamaño y complejidad, realiza la mayor parte del procesamiento sensorial y motor, así como funciones que incluyen en razonamiento, la planificación, el procesamiento del lenguaje o el reconocimiento de patrones.




Figura 2.2: Centros nerviosos del cerebro [13]

Igualmente, el cerebro se compone en dos hemisferios de estructura similar que se conocen como hemisferio izquierdo y derecho, los cuales se encuentran recubiertos por la corteza. Asimismo, en la parte interna se concentran las conexiones neuronales (axones) entre la corteza y los nervios. Funcionalmente, el hemisferio izquierdo controla funciones como la habilidad numérica, la capacidad lógica, la escritura y la lectura, al igual que la parte derecha del cuerpo humano. Por su parte, el hemisferio derecho se enfoca a facultades relacionadas con las artes, la percepción espacial y el movimiento de las extremidades de la parte izquierda.

Los hemisferios se dividen a su vez en lóbulos, y se pueden distinguir cuatro tipos, a través de los cuales se realizan ciertas funciones:

1. **Lóbulo frontal.** Sus funciones afectan a diferentes áreas de comportamiento humano como el control de las emociones, el pensamiento, el aprendizaje, el juicio moral o la capacidad de razonamiento. Del mismo modo, también destaca su función en el habla y en la capacidad de planificación y ejecución del movimiento.
2. **Lóbulo occipital.** Recibe e interpreta las señales oculares, permitiendo a otros lóbulos el procesamiento de las mismas. Tiene una función importante en el reconocimiento del entorno.
3. **Lóbulo parietal.** Su función principal consiste en la interpretación de las señales sensoriales y el control espacial. Este área permite asociar la información recibida desde la piel, las articulaciones y los músculos al tacto o dolor físico. Del mismo modo, crea asociaciones entre la información visual procesada en el lóbulo occipital y otras áreas corticales.
4. **Lóbulo temporal.** Sus funciones más destacadas afectan a la memoria y a la recepción y procesamiento de las señales auditivas, por lo que realiza una función clave en el entendimiento del habla. De igual modo, se encarga de sentir emociones y percibir formas y colores.

A pesar de la distribución de la función humana mostrada, en caso de producirse una lesión en una de las áreas anteriores, las neuronas que han permanecido intactas son capaces de crear nuevas conexiones que sustituyen a las deterioradas, sobre todo en caso de daño leve. La reorganización de estas conexiones se conoce como *plasticidad* ([9]) e implica la necesidad de un entrenamiento intensivo durante una ventana de tiempo reducida después de la lesión, de forma que se cree la red neuronal necesaria para asumir las funciones afectadas.

## 2.3. La Médula Espinal

### 2.3.1. Estructura y Funciones de la Médula Espinal

La médula espinal actúa como elemento de comunicación entre el cerebro y el resto del organismo y a través de ella circulan estímulos nerviosos e instrucciones cerebrales. Por un lado, transmite información proveniente de los nervios periféricos situados en distintas regiones corporales hasta el cerebro. Por otro, transmite los impulsos generados por el cerebro de manera descendente hasta los músculos y vasos sanguíneos a través de los nervios que salen de ella.

Al igual que el cerebro, la médula espinal se encuentra protegida por las meninges y, a su vez, por la columna vertebral. Morfológicamente, se extiende desde la base del cráneo hasta la segunda vértebra lumbar. Su volumen está en torno al 2 % del total del SNC y tiene una longitud de entre 42 y 45 cm en un adulto, utilizando dos tercios de la






Figura 2.3: Distribución de la médula espinal [14]

longitud del canal espinal. Tiene un diámetro de alrededor de 1 cm en su punto más ancho y contiene 31 segmentos, asociados a pares de nervios espinales [12].

## 2.4. Interfaces Cerebro Máquina

Los sistemas capaces de capturar, procesar e interpretar los pensamientos e intenciones de un sujeto a partir de los impulsos existentes en su cerebro se denominan interfaces cerebro-computador (BCI del inglés Brain-Computer Interfaces), interfaces mente-máquina (MMI del inglés Mind-Machine Interface) o interfaces cerebro-máquina (BMI del inglés Brain-Machine Interfaces) [15, 16, 17]. En estos sistemas los usuarios son capaces de manipular su actividad cerebral de forma voluntaria para producir señales de control, en lugar de usar movimientos.

La importancia de este tipo de sistemas radica en su ámbito de aplicación. En casos donde la función cerebral se ha dañado recientemente este tipo de tecnologías se puede integrar con elementos rehabilitadores, facilitando la recuperación del paciente. Por otra parte, para personas con daños irreparables, como por ejemplo pérdidas motoras derivadas de lesiones de médula espinal, resulta posible integrar estos sistemas con otras tecnologías asistenciales para mejorar la capacidad del paciente de relacionarse con su entorno.

La arquitectura fundamental de estos sistemas se presenta en la Figura 2.4, donde se pueden distinguir tres partes:

1. Captura de Datos. Se lleva a cabo la lectura los potenciales de acción de las neuronas del cerebro del usuario o paciente, adquiriendo señales analógicas que son amplificadas y digitalmente tratadas para su posterior procesamiento.



Figura 2.4: Esquema general de un sistema BCI

2. **Preprocesamiento.** Esta etapa comprende dos partes, la primera de ellas incluye el tratamiento de la señal capturada con el objetivo de incrementar su calidad. La segunda se centra en realizar los cálculos necesarios para transformar la señal tratada en un vector de características que contenga la información más relevante posible para el escenario del problema.
3. **Clasificación.** En esta parte del proceso, se utiliza un clasificador para determinar la respuesta del sistema. Como resultado, se genera una salida que define el comando de control a llevar a cabo.

Cabe destacar que un sistema BCI únicamente provee una unidad de control y que la utilidad de éste depende del escenario en el que se aplique. Por tanto, además de los campos relacionados con la rehabilitación y las tecnologías asistenciales, estos sistemas tienen innumerables aplicaciones en áreas desde el movimiento y control de objetos hasta los estudios de mercado.

#### 2.4.1. Procedimientos de Medida de la Actividad Cerebral

El modo de obtención de las señales cerebrales queda fundamentalmente limitado por las características del dispositivo al que cada equipo de investigación tiene acceso. Atendiendo al procedimiento de adquisición de datos se puede distinguir entre técnicas invasivas y no invasivas.

##### 1. Procedimientos Invasivos

Los sistemas BCI invasivos se basan en la implantación de microelectrodos o micro arrays sobre la corteza cerebral que permiten el acoplamiento a dispositivos externos [18]. Para ello es necesario un procedimiento quirúrgico en el que se elimina una pequeña superficie del cráneo y de la dura madre.




Figura 2.5: Relación entre la ubicación de los elementos sensores y las tecnologías para la captura de las señales cerebrales [6]

Estos equipos poseen la ventaja de que, al situar los electrodos en una ubicación más cercana al cerebro, detectan los potenciales cerebrales con una mayor precisión. Así, las señales capturadas tienen una menor atenuación. De hecho el rango de amplitudes detectables está entre  $50$  y  $100\mu\text{V}$  comparado con los  $10\text{-}20\mu\text{V}$  cuando los potenciales cerebrales se leen sobre el cuero cabelludo.

Igualmente, la resolución temporal es mayor. Por ejemplo, implantar los sensores bajo el cráneo habilita el acceso a un ancho de banda entre  $0$  a  $500\text{Hz}$ , en comparación con los  $0$  a  $50\text{Hz}$  en el cuero cabelludo. Igualmente, la detección es más precisa dado que la ubicación de los elementos de captura de datos también conlleva un mejor aislamiento ante el ruido ambiental [19].

Salvada la dificultad del procedimiento quirúrgico, la mayor desventaja de estos sistemas es la durabilidad. La calidad en la lectura en los sistemas BCI invasivos va decayendo con el tiempo, algo que dificulta su uso en el control de prótesis, donde se requiere una duración de años. A su vez, se han de destacar otros parámetros que afectan negativamente al implante tales como la aparición de tejido cicatrizante y la posibilidad de que las estructuras neuronales se desalineen de la zona objetivo o cambien con el tiempo, lo que puede provocar que se deje de leer información de las neuronas más relevantes [20].

Existe una fuerte tendencia en la industria a la miniaturización y a la telemetría con el objetivo de disminuir las potenciales causas de infección e incrementar la robustez de estos sistemas [21].

### ■ *Electrocorticografía (ECoG)*

La electrocorticografía es una técnica fundamentalmente asociada al tratamiento de la epilepsia severa en pacientes en los que la medicación no resulta efectiva. En estos casos, el tratamiento se basa en extirpar la zona causante del ataque epiléptico, para lo cual es necesario tanto identificar la ubicación específica de los focos epilépticos como analizar la funcionalidad de la zona que se pudiese dañar durante el procedimiento quirúrgico [22].

En estos casos, se utilizan métodos encefalográficos (EEG del inglés electroencephalography) o basados en resonancia magnética (MRI del inglés Magnetic Resonance Imaging) para analizar de una forma no invasiva el cerebro del paciente y localizar la zona afectada. Hecho esto se procede a la implantación de una tira de electrodos bajo el cráneo, normalmente directamente sobre la localización dañada, bajo la duramadre. Estos implantes sólo tienen como función mejorar el conocimiento de la zona por parte de los neurólogos y neurocirujanos y el paciente los suele llevar entre una y dos semanas [23]. Después del tiempo de monitorización, el array de electrodos se retira en el mismo procedimiento quirúrgico que la extirpación de la zona epiléptica.

Cabe destacar que dependiendo del número y tamaño del array de microelectrodos, es posible insertarlos en regiones más profundas del cerebro. Como ventaja sobre los procedimientos invasivos tradicionales se encuentra la tipología física de la superficie de actuación. Por un lado, las tiras de electrodos son mecánicamente más robustas que los electrodos que penetran en el cerebro y, por tanto, más duraderas [21]. Por otro, las medidas tomadas con ECoG cubren grandes poblaciones de células, prolongando la relevancia de la medición en el tiempo.

## 2. Procedimientos no Invasivos

Los procedimientos no invasivos incluyen todas aquellas tecnologías de medida de la actividad cerebral que no requieren ningún tipo de cirugía para su utilización. Esta característica es la que los convierte en la opción predilecta para la medida de la actividad cerebral en humanos.

Dentro de los sistemas BCI no invasivos existen diferentes variantes atendiendo al principio utilizado para leer la información cerebral. Entre ellas se pueden distinguir la magneto encefalografía (MEG del inglés Magneto Encephalography), la imagen por resonancia magnética funcional (fMRI del inglés functional Magnetic Resonance Imaging), la tomografía por emisión de positrones (PET del inglés Position Emission Tomography), la tecnología de espectroscopia próxima al infrarojo (NIRS del inglés Near Infrared Spectroscopy) o los sistemas basados en EEG.

La MEG precisa de la utilización de un equipo de generación de ondas magnéticas que permite leer ondas neuromagnéticas en el cerebro. Su principio de utilización requiere un equipo similar al que se muestra en la Figura 2.6 y la adecuación de una sala magnéticamente aislada.



Figura 2.6: Sistema BCI basado en MEG [24]

Los sistemas fMRI permiten mostrar la evolución de las diferentes áreas del cerebro durante la realización de tareas. La técnica utilizada se fundamenta en la medición de las variaciones en el magnetismo local de acuerdo a la vasodilatación que ocurre en la parte del cerebro encargada de la acción. Los equipos fMRI no son muy diferentes de los de resonancia magnética tradicionales.

La tecnología PET monitoriza el estado de un fármaco de vida corta que es inyectado al paciente antes del experimento y que, a partir de una reacción química con los elementos químicos propios del cuerpo humano, genera fotones que los detectores PET pueden detectar. La disposición de estos sistemas es muy similar a la de los dispositivos fMRI.

Los sistemas de tipo NIRS permiten medir los cambios de concentración de la hemoglobina en los vasos sanguíneos que alimentan al cerebro a partir de la generación y detección de ondas en el espectro entre 800 y 2500 nm. La reflexión de estas ondas se relaciona con los cambios en el movimiento sanguíneo debidos a la activación neuronal. De esta forma ofrecen una serie de valores para las zonas en las que los sensores se han situado no permitiendo, al contrario del caso anterior, una imagen completa de todas las zonas de cerebro. Como mayor desventaja, la respuesta hemodinámica tarda entre cinco y diez segundos en aparecer después del evento a monitorizar, lo que limita su uso en aplicaciones de tiempo real y condiciona el intervalo entre estímulos consecutivos. La Figura 2.7b muestra un sistema de este tipo.

En los equipos EEG una serie de sensores se posicionan sobre el cuero cabelludo del sujeto, de forma que se puede realizar una exploración neurofisiológica del cerebro a



(a) fMRI [25]



(b) NIRS [26]

Figura 2.7: Sistemas BCI de captura de datos no invasivos

partir sus registros de actividad bioeléctrica, que aparecen debido a fluctuaciones en el voltaje resultantes de las corrientes iónicas existentes en las neuronas. Dado que estas señales se transmiten instantáneamente hacia la piel a través del cráneo y el resto de tejidos, estos sistemas presentan una muy buena resolución temporal.

Por contra, dado que únicamente se captura información en determinados puntos del cuero cabelludo, la resolución espacial es reducida.

No obstante, la resolución temporal y las características ergonómicas de los dispositivos de captura de datos convierten a los sistemas basados en EEG en la técnica BCI más utilizada en el ámbito científico, estando presentes en más del 80 % de la literatura [27].

#### 2.4.2. Componentes de un sistema EEG

Dado que los equipos BCI de obtención de datos utilizados para la realización de esta tesis doctoral son de tipo EEG, este punto profundiza en los fundamentos de los mismos. Tal y como se ha detallado en apartados anteriores de este documento, existen generalmente tres etapas diferenciadas en el procesamiento de un sistema BCI: captura de datos, procesamiento y clasificación (Figura 2.4).

En un dispositivo EEG, la captura de datos se realiza utilizando una serie de sensores ubicados sobre el cuero cabelludo del usuario o paciente en posiciones normalizadas definidas a partir del sistema de posicionamiento 10-20, estandarizado por la Sociedad Americana de Encefalografía. Este modelo provee una normalización en la distribución de los electrodos que posibilita repetitividad en la captura de datos en 19 posiciones. Éstas se encuentran definidas por la subdivisión iterativa de arcos determinados en el cuero cabelludo a un 10 % o 20 % de la longitud total de la cabeza del usuario, dependiendo del número de electrodos a colocar y de la distancia entre los puntos definidos entre la parte delantera y la trasera de cabeza y aquellos definidos horizontalmente detrás de las orejas. Los nombres de las posiciones comienzan con una letra que identifica dónde se





pasan a denominarse secos.

Además de los elementos de captura de información, los sistemas EEG suelen incorporar componentes adicionales para amplificar, filtrar y transmitir los datos capturados. Tomando como ejemplo la Figura 2.8 estos equipos incluyen la alimentación necesaria para el funcionamiento del sistema y generalmente amplificadores y filtros para mejorar la calidad de la salida del mismo. Igualmente, resulta indispensable poder conectar estos aparatos a otros equipos que permitan completar las sucesivas etapas de procesamiento. Dependiendo el sistema, esos componentes pueden aparecer como elementos diferenciados o embutidos en el propio dispositivo EEG.

Los elementos físicos necesarios para llevar a cabo la conversión de los potenciales capturados a un vector de características y la clasificación se suelen incluir como elementos adicionales. En la literatura aparecen desde integraciones en dispositivos empujados hasta la utilización de ordenadores de sobre mesa o portátiles convencionales.

### 2.4.3. Señales detectadas por los sistemas BCI basados en EEG

De acuerdo a cómo se activan las señales cerebrales se pueden distinguir dos diferentes paradigmas: potenciales espontáneos y evocados [20, 30]. Los primeros se aparecen a partir de pensamientos específicos sin ningún estímulo sensorial adicional. Ejemplos de este tipo incluyen:

1. Potenciales corticales lentos (*SCP del inglés Slow Cortical Potentials*). Se basan en las variaciones positivas y negativas de voltaje generadas en la corteza cerebral durante los estados de preparación conductual o cognitiva y durante los estados que motivan la aprehensión y el miedo ([31]). Estas variaciones se producen a unas frecuencias muy pequeñas (por debajo de 4Hz), presentando una extensión temporal entre unos milisegundos y varios segundos. Los SCPs negativos son los que realmente denotan la actividad, indicando los positivos una reducción en la misma. La importancia de los mismos redunda en que los usuarios pueden controlarlos voluntariamente en las áreas centrales y frontales del cerebro después de entre una y cinco sesiones de entrenamiento de 1 hora ([32]). Como nota negativa, proveen un canal de comunicaciones demasiado lento.
2. Ritmos Sensorimotrices e imaginación de movimiento. El cerebro humano presenta variaciones en la potencia de las señales capturadas en frecuencias específicas. Cuando dicha actividad se produce en la corteza motora, estos cambios se denominan ritmos, y los más relevantes son el  $\mu$  (10-12Hz) y el  $\beta$  (18-25Hz) ([33]). Como paso previo a la realización de un movimiento, se genera un descenso de los valores de actividad en dichos ritmos, en especial en la parte contralateral al movimiento. Este decremento se denomina desincronización relacionada al evento (*ERD del inglés Event-related Desynchronization*), mientras que el proceso opuesto, que ocurre cuando la persona vuelve al estado de relajación, se denomina sincronización relacionada al evento (*ERS del inglés Event-related Synchronization*). El interés en estos ritmos se fundamenta en su aparición incluso durante la imaginación del movimiento ([34, 35, 36]).

Asímismo, los patrones cerebrales pueden generarse como respuesta a estímulos externos. En este caso, el estudio de las señales EEG se fundamenta en la búsqueda de tales patrones y en la utilización de los mismos para detectar la intención del usuario. Entre este tipo de patrones se distinguen:

1. Potenciales P300. Cuando el cerebro detecta un evento sonoro, visual o sensorial significativo de forma inesperada intercalado en una secuencia de eventos frecuentes, se aprecia la generación de un pico positivo alrededor de 300ms después del mismo de forma automática. Este pico positivo se mide en la zona centro parietal del cerebro y su amplitud y latencia es muy variable entre usuarios. Los sistemas basados en este tipo de patrón EEG no requieren entrenamiento previo, si bien es necesario mantener al usuario concentrado en el experimento para que la señal siga siendo detectable [37]. El método clásico para generar el potencial P300 se denomina paradigma *oddball* [38], en éste las celdas de una matriz se agrupan en filas y columnas que se van resaltando de forma aleatoria, mientras los sujetos tienen que deletrear mentalmente contando el número de destellos ocurridos en la posición deseada. Fazel-Rezai et al. compilan en la referencia [39] tanto las variaciones más significativas en el paradigma *oddball* como los retos futuros de la tecnología BCI basada en P300.
2. Potenciales visualmente evocados de estado estatico (*SSVEP del inglés Static-State Visually Evoked Potentials*). Estos potenciales aparecen la zona de la corteza visual cuando se expone un sujeto a un estímulo parpadeante a una cierta frecuencia en el rango entre 3 y 75Hz. En estos casos, se puede detectar una señal cerebral de la misma frecuencia y sus armónicos, por lo que se pueden distinguir entre diferentes estímulos cuando éstos se evocan utilizando frecuencias distintas. Los investigadores han conseguido tasas de transferencia de información de hasta 58 bits por minuto [40]
3. Comienzo-de-movimiento potenciales visuales evocados (*mVEP del inglés motion-onset Visual Evoked Potentials*). En este caso se distinguen los potenciales P100, P200 y N200, siendo este último el más significativo [41]. El principio de funcionamiento se fundamenta en un modelo similar al *oddball* en los sistemas P300, aunque en estos casos se sustituye la cuadrícula de letras por una de botones, dentro de los cuales se realiza algún tipo de movimiento. El potencial N200 aparece como una inflexión negativa de la señal alrededor de 200 ms después del comienzo del estímulo sobre la zona parieto-occipital del cerebro, que se puede utilizar como fundamento para la construcción de un sistema BCI. Entre las ventajas de este tipo de sistemas se encuentran una menor variabilidad intra usuario y la reducción del cansancio al necesitar poca luminosidad y contraste para la realización del experimento (al contrario que en P300) [42, 43].

Del mismo modo, también se pueden encontrar sistemas BCI híbridos combinando la detección diferentes tipos de señales EEG de forma simultánea o secuencial con el objetivo de mejorar su rendimiento global [44]. En los sistemas híbridos simultáneos los diferentes paradigmas EEG se combinan para crear un conjunto de datos más rico, de forma que el

clasificador sea más preciso [45]. Los sistemas BCI híbridos secuenciales dividen las tareas complicadas en etapas que se pueden llevar a cabo de un modo más sencillo, proveyendo a los usuarios de mayores grados de libertad ([46, 40]). Por contra, uno de los mayores retos en la utilización de estos sistemas es su interfaz con el usuario, dado que éste sufre un cansancio mayor al tener que mezclar diferentes técnicas BCI para el control de un mismo sistema.

#### 2.4.4. Protocolo de comunicaciones

En el estudio de sistemas BCI se establece generalmente el uso de dos modos de funcionamiento: el modo síncrono y el asíncrono. En los sistemas síncronos se presentan estímulos al usuario a intervalos regulares, lo que facilita su detección y el análisis posterior de los datos. En estos casos, el sistema induce al usuario a tomar una decisión en un determinado instante de tiempo, por lo que controla el momento exacto en el que ocurre la transición entre estados.

Sin embargo, en los sistemas asíncronos, el sujeto es libre de iniciar y terminar cualquier tipo de pensamiento en el instante de tiempo que desee. Este protocolo de comunicaciones es más natural para el usuario pero presenta una dificultad añadida en cuanto a la detección de estos cambios de estado. El trabajo de investigación desarrollado en el marco de este trabajo doctoral se fundamenta en el paradigma asíncrono.

### 2.5. Equipos de Captura de Datos EEG Profesionales

El rendimiento de los sistemas BCI presenta una relación directa con la calidad de sus componentes, que determinan su precisión en la detección de las señales cerebrales. La diminuta amplitud de los potenciales eléctricos detectables sobre el cuero cabelludo provoca que se vean afectados por multitud de artefactos, proviniento éstos tanto del cuerpo humano (latidos del corazón, parpadeos o movimiento de las mandíbulas) como del entorno (interferencias electromagnéticas), que contribuyen a incrementar la componente de ruido asociada a la señal EEG objetivo. Como resulta evidente, el coste de los sistemas EEG de captura de datos es mayor a medida que los componentes electrónicos utilizados en su manufactura son de una mayor calidad, permitiendo una lectura más precisa de las bioseñales cerebrales.

El modelo de comercialización de los mismos permite cierto grado de personalización, pudiendo combinar sensores, mallas y amplificadores de varios tipos. De hecho, como los amplificadores tienen un número determinado de canales, el coste de sistemas EEG queda determinado no sólo por el tipo de amplificador seleccionado sino también por el número de ellos, dependiendo del número de canales que se desee implementar.

A continuación se incluye una revisión de algunos de estos equipos, el coste de los mismos no ha sido calculado debido al número de combinaciones diferentes que se pueden realizar entre sus diferentes componentes.

1. Brain Products. El número de diferentes combinaciones posible es destacable. Se comercializan un total de cuatro tipos diferentes de electrodos, un módulo de trans-

Tabla 2.1: Dispositivos de captura de datos EEG profesionales

Fabricante	Dispositivo	Número Sensores	Máximo Combinable	Tipo sensores	Frecuencia muestreo	Transmisión Señal	Suite	SDKs
Brain Products	actiCHamp	32	160	a elegir	50kHz - 10 kHz	USB	Varias	Gratuita
Brain Products	BrainAmp Standard	32	256	a elegir	5kHz por canal	Óptica	Varias	Gratuita
Brain Products	BrainAmp ExG	8 o 16	-	a elegir	5kHz por canal	Óptica	Varias	Gratuita
Brain Products	V-Amp	8 o 16	-	a elegir	2kHz por canal	USB	Varias	Gratuita
Biosemi	ActiveTwo	8	256 + 8	húmedos	16 kHz - 2 kHz	Óptica	LabVIEW	Gratuita
ANT Neuro	eego mylab	32/64	256	-	16 kHz	Inalámbrica	Varias	Gratuita
ANT Neuro	eego sports	32/64	64	-	2 kHz	Inalámbrica	Varias	Gratuita
ANT Neuro	eego rt	16/32/64	64	-	2 kHz	Inalámbrica	Varias	Gratuita
ANT Neuro	eego mini	8	24	-	2 kHz	Inalámbrica	Varias	Gratuita
g.tec	HIamp	64+16	256	a elegir	38.4 kHz	USB	Varias	De pago
g.tec	USBamp	8/16	64	a elegir	38.4 kHz	USB	Varias	De pago
g.tec	Nautilus	8/16	64	a elegir	500 Hz - 256 Hz	Inalámbrica	Varias	De pago
Neuroelectrics	Enobio	8, 20 o 32	-	a elegir	500 Hz por canal	Inalámbrica	Nube	Gratuita

misión de datos inalámbrico y ocho tipos de amplificadores. Entre los diferentes tipos de sensores se encuentran elementos activos (actiCAP 16 y 128 canales), pasivos (EasyCap hasta 128 canales y BrainCap hasta 256) y secos (actiCAP Xpress, 16 canales sólo para V-Amp). Un resumen de los modelos de amplificador comercializados puede consultarse en la Tabla 2.1. Del mismo modo, ofrece diferentes alternativas en el acceso a los datos capturados. Éste se puede realizar a través del SDK provisto de forma gratuita por Brain Products, que no incluye ningún tipo de software de grabación de sesiones. Para actiCHamp, se puede acceder a los datos capturados desde NeuroRT, OpenViBE, BCILAB, BCI 2000 y BCI2VR. Sin embargo, para los otros amplificadores comercializados, sólo es posible acceder de forma directa desde NeuroRT y OpenViBE. Para cualquiera de las otras herramientas es necesario suscribirse al paquete BrainVision, cuyo coste es del 300 euros mensuales.



Figura 2.10: Gama de amplificadores comercializados por Brain Products [47]

2. Biosemi ActiveTwo. Biosemi comercializa un único modelo, que se puede adquirir con diferentes configuraciones en el número de sensores (desde 8 a 256) dependiendo el número de módulos incluidos en su conversor analógico a digital. Sólomente es posible adquirir sensores activos húmedos y el SDK de acceso a los datos provistos se basa en LabVIEW. Cabe destacar que, al contrario de la mayoría de los fabricantes, se puede encontrar el precio de estos sistemas en su página web, situándose entre los 13.500 y los 75.000 euros para una configuración típica entre 8 y 256 canales.



Figura 2.11: Biosemi Active Two en una configuración de 128 canales [28]

3. ANT Neuro. Para comenzar conviene destacar que todos los sistemas EEG de ANT Neuro cuentan con la certificación CE Class IIa para aplicaciones médicas y utilizan la misma tecnología en sus sensores, llamada blindaje activo. A partir de ahí, existen cuatro familias de productos distintos: eego mylab, eego sports, eego rt y eego mini. Es destacable que todos ellos son portátiles, con una autonomía anunciada de entre 5 (eego mylab y rt) y 6 horas (eego sports). La versión eego sports incluye sensores de respiración, temperatura, conductancia de la piel y aceleración en el paquere pro. De la misma forma, incluye una mochila, una maleta y una tablet de 8" con sistema operativo Windows 8, de forma que el usuario pueda ver su comportamiento en movimiento. La última serie en ser comercializada ha sido la eego mini, que se basa en módulos de 8 canales apilables hasta conformar un sistema de 24 canales. En todos los casos, ANT proporciona acceso a los datos a través de una API propietaria basada en C++. No obstante, también es posible la conexión desde otras herramientas como OpenVibe, EEGlab/LSL, BCI2000 y Matlab mex.
4. g.tec. La oferta de g.tec se basa en ofrecer diferentes opciones en la mayoría de los componentes, permitiendo la creación de la solución más personalizada posible atendiendo a las necesidades del comprador. Esta filosofía se aplica fundamentalmente a la comercialización de los sistemas HIamp y USBamp. Estos dos dispositivos permiten una personalización total disponiendo de multitud de tipos de sensores secos y húmedos, mientras que la configuración del número de canales se basa en la cantidad de módulos que se desee adquirir. Esto permite a compradores expertos la definición y adquisición del modelo más adaptado a sus necesidades, pero supone una barrera de entrada para los compradores sin ese grado de conocimiento. Por tanto, también existe un paquete llamado Nautilus que incluye todos los componentes de un sistema general, únicamente dejando a elección del comprador la elección de la tecnología de los electrodos (secos o húmedos), entre los que se pueden elegir sensores secos g.Sahara. El Nautilus se basa en tecnología inalámbrica tanto en la transmisión de datos como en la carga del dispositivo, anunciando unas 10 horas de autonomía. Para los desarrolladores, existen diferentes APIs y drivers para varios lenguajes de programación. Existe también la posibilidad de acceder a los datos desde BCI 2000,



Figura 2.12: ANT Neuro eego mylab en una configuración de 128 canales [48]

dado que los componentes provistos por g.tec se encuentran certificados, o a través del paquete g.BCIsys creado especialmente para Matlab/Simulink. El coste anunciado para el amplificador g.HIamp se encuentra entre los 31.300 y los 73.000 euros y el g.USBamp se inicia con un coste de 11.350 euros, precios que no incluyen sensores, acceso a APIs o software adicional.



Figura 2.13: Amplificador g.tec HIamp [49]

5. NeuroElectrics Enobio. El sistema Enobio se puede adquirir con 8, 20 o 32 canales. Existe una amplia variedad de electrodos disponibles en diferentes materiales tanto en combinaciones con sensores secos como con sensores húmedos. Una de las características fundamentales de este tipo de sistemas es que son inalámbricos y se conectan por Bluetooth a los dispositivos receptores de los datos. El casco pesa 65 gramos, posee un acelerómetro de tres coordenadas y permite utilizar una tarjeta de tipo micro SD para grabar datos en el mismo equipo. La batería anuncia una duración en torno a 15 horas. Destaca también su compatibilidad con plataformas de desa-

rollo BCI como BCI2000, OpenVibe, PureData y Processing, proveyendo asimismo APIs para C y Matlab. Al igual para que para otros dispositivos, NeuroElectrics también ofrece suites de software más avanzadas para el acceso y tratamiento de los datos bajo licencia, entre estas destacan MatNIC para Matlab o Neurosurfer, que es capaz de mostrar y realizar análisis de datos en tiempo real.



Figura 2.14: NeuroElectrics Enobio en una configuración de 32 canales [50]

## 2.6. Equipos de Captura de Datos EEG de Bajo Coste

Además de los equipos profesionales mostrados como ejemplo en la sección anterior, existe una tendencia a acercar la tecnología EEG al público en general, inicialmente a través de sistemas EEG de bajo coste asociados fundamentalmente a la industria del video juego y la meditación. Si bien la aspiración de éstos no fue inicialmente la comunidad médica o científica, sí que han recibido una especial atención por parte de los investigadores, quienes los han evaluado e incluido dentro de su ámbito de trabajo. Asimismo, los avances tanto en las técnicas de procesamiento como en las de clasificación han llevado a cuestionar hasta qué punto los sistemas de captura de datos EEG son relevantes en la precisión global de los sistemas BCI.

Atendiendo a este interés los fabricantes proveen entornos de desarrollo que permiten realizar aplicaciones utilizando estos dispositivos, así como acceder a los datos capturados sin ningún procesamiento previo. La tabla siguiente muestra un resumen de los equipos de captura de datos EEG que actualmente se pueden adquirir por un coste inferior a los 1.000 euros y cuyos fabricantes proveen la capacidad de acceder a los datos capturados.

A continuación se realiza un pequeño resumen de las principales características de cada uno de los dispositivos que aparece en la tabla anterior.

1. Neurosky Mindwave. El dispositivo se compone un brazo donde se sitúa el único sensor de obtención de datos EEG. Está fabricado en acero inoxidable e incluye una pinza en la que se encuentra el electrodo de referencia. El sensor EEG se ubica en la posición FP1 del sistema 10-20. El casco se comunica via Bluetooth BT/BLE en



Tabla 2.2: Dispositivos de captura de datos EEG de bajo coste

Fabricante	Dispositivo	Coste (\$)	Número Sens	Tipo	Frec. muest	Duración batería (h)	Formato datos	Plataforma	SDKs	Coste SDK (\$)
Neurosky	Mindwave	99,99	1+1	Secos	512Hz	6-8	CSV	Windows	NeuroView	499,99
Neurosky	Mindwave Mobile	99,99	1+1	Secos	512Hz	6-8	CSV	Mac Os Windows Mac Os Android IOS	NeuroSkyLab NeuroView NeuroSkyLab	499,99
Emotiv	EPOC+	799,99	14+2	Húmedos	128Hz	12 (6 con BT)	EDF	Windows Mac Os Linux iOS	Pure EEG	49/mes
Emotiv	Insight	299,99	5+2	Secos	128Hz	8 (4 con BT)	EDF	Android Windows Mac Os Linux iOS	Pure EEG	49/mes
OpenBCI	Ganglion	199,99 + 799,99 casco	4	Secos	125Hz	-	EDF	Android Windows Mac Os Linux	OpenBCI GUI	Gratuito
OpenBCI	Cyton Biosensing	499,99 + 799,99 casco	8	Secos	125Hz	-	EDF	Windows Mac Os Linux	OpenBCI GUI	Gratuito
Intreraxon	Muse	299,00	4+3	Secos	256Hz	10	Muse	Windows Mac Os iOS Android	MuseLab Muse Player	Gratuito

modo dual. Para tareas de investigación es necesario adquirir de forma independiente la aplicación NeuroSkyLab, que permite el acceso a los datos raw capturados a través de Matlab y que sólo funciona para entornos de tipo Windows.

- Neurosky Mindwave Mobile. La funcionalidad es idéntica a la detallada para Neurosky Mindwave. La única diferencia estriba en que este casco permite su uso con plataformas móviles de tipo Android e IOS.
- Emotiv EPOC+. Este dispositivo utiliza 14 sensores activos situados sobre diferentes posiciones del cuero cabelludo del usuario para capturar los cambios en los potenciales eléctricos del cerebro. Cada sensor contiene una almohadilla que se debe humedecer con una solución salina antes de situarse en contacto directo con el cuero cabelludo. Debido al número de sensores disponibles y a las características que se van a exponer con más detalle en la siguiente sección, éste ha sido el dispositivo elegido para el estudio propuesto en esta tesis doctoral por que se incluye un apartado completo para describirlo en más detalle.
- Emotiv Insight. Este auricular móvil contiene 5 sensores de un material a base de polímeros que no requiere la aplicación de ningún gel o solución salina adicional junto con dos sensores de referencia. Las posiciones donde se sitúan en el sistema 10-20 son la AF3, AF4, T7, T8 y Pz. El sistema ofrece datos a una tasa de 128Hz y los transfiere desde el auricular utilizando tecnología bluetooth 4.0. Siguiendo el modelo Emotiv, el acceso a los datos capturados se ha de realizar a través del pago mensual en un modelo de suscripción llamado EmotivPRO.



Figura 2.15: NeuroSky MindWave [51]




(a) Emotiv EPOC+




(b) Emotiv Insight

Figura 2.16: Dispositivos de captura de datos EEG Emotiv [52]

5. OpenBCI Ganglion. La peculiaridad sobre los productos desarrollados por OpenBCI es la división que existe entre el casco físico y el hardware de procesamiento de los datos capturados. Existe un único casco disponible, que se denomina Ultracortex Mark IV, cuya estructura se puede tanto adquirir como imprimir en una impresora 3D, lo que facilita futuras reparaciones del dispositivo. El coste del mismo se encuentra, para hasta 8 canales, entre los \$349 de la versión que debe imprimir el comprador y los \$799 de la versión totalmente ensamblada, e incluye los sensores secos y los conectores, excluyendo la placa seleccionada. Respecto al hardware de procesado, la placa Ganglion cuenta con 4 canales de entrada analógicos, además de la alimentación o la conexión a tierra. Igualmente, incorpora 12 pines para configurar entradas y salidas digitales.
6. OpenBCI Cyton Biosensing. En este caso, la placa base permite la conexión de hasta 8 canales de entrada y la capacidad de procesamiento se amplía a tal efecto. Al igual




(a) Imagen del casco




(b) Posiciones sensores sistema 10-20

Figura 2.17: Ultracortex Mark IV [53]

que para el ejemplo anterior, la comunicación se realiza a través de Bluetooth 4.0 por lo que se incluye un dispositivo USB para gestionar la misma. Cabe destacar en los sistemas OpenBCI las herramientas de desarrollo y los SDK disponibles. Dado que OpenBCI es una plataforma de software abierto, los desarrolladores tienen acceso tanto a OpenBCI GUI, que actúa como un interfaz gráfico entre los sistemas y el usuario, como a herramientas que permiten el acceso a los datos desde Matlab y OpenViBE, además de utilizando lenguajes como Python o Java. También existe la posibilidad de conectar un sistema Daisy Biosensing, para llegar a obtener hasta 16 canales de datos.



(a) Placa Open BCI Ganglion



(b) Placa Open BCI Cyton Biosensing

Figura 2.18: Placas de procesamiento de datos Open BCI [53]

7. Interaxon Muse. Es un dispositivo pensado para la ayuda en la relajación de sus usuarios, que propone a los mismos ciertos retos para mejorar esta capacidad. La aplicación se basa en la medición de la actividad cerebral para determinar el nivel de tensión del usuario y en la reproducción de sonidos atmosféricos de diferente

intensidad según su estado. Se compone de 7 sensores secos en las posiciones FP1, FP2, 2 en los mastoides (en las orejas) y 3 de ellos de referencia en la frente entre FP1 y FP2. El dispositivo se comunica a través de Bluetooth 4.0 BTL y la señal de salida capturada se encuentra entre 0 y 100Hz. El acceso a señal EEG se debe realizar a través del Muse Research Tool Kit, disponible de forma gratuita.



Figura 2.19: Interaxon Muse [54]

### 2.6.1. Emotiv EPOC

Dado que el equipo de captura de datos de bajo coste utilizado en esta tesis doctoral es el Emotiv EPOC, se profundiza a partir de este apartado en sus características y utilización dentro de la comunidad científica.

Emotiv Systems fue fundada en 2003 por cuatro científicos después de años colaboración con la Universidad de Sidney y la Universidad Tecnológica de Sydney. Los nombres de los mismos son el profesor Allan Snyder, el diseñador electrónico Neil Weste, y los emprendedores Tan Le y Nam Do. Como fruto de esta sociedad, en Junio de 2009 se lanzó a la venta el Emotiv EPOC (Figura 2.16a).

Este sistema de adquisición de señales EEG ha recibido diferentes nombres a lo largo del tiempo: EPOC, Emotiv EEG y más recientemente EPOC+. El EPOC+ no presenta diferencias en cuanto a la presentación externa y las características, tecnología o posicionamiento de los sensores. No obstante, Emotiv ha incluido mejoras como el módulo de bluetooth no propietario que permite la conexión el casco a dispositivos móviles, ha mejorado el acelerómetro, ha incluido un nuevo giroscopio para tener datos en los tres ejes y ha añadido un magnetómetro. Asimismo, el modelo de acceso a los datos en raw a pasado de ser gratuito a requerir una suscripción. Por ejemplo, el SDK necesario para acceder datos raw tiene un coste de mensual de \$99.

Puesto que se han tomado datos con el Emotiv EPOC Reseach Edition y con el Emotiv EEG (versiones anteriores a EPOC+), las características detalladas en este apartado se corresponden de forma precisa con estos modelos concretos de dispositivo. El Emotiv EEG cuenta con 16 electrodos superficiales de contacto fabricados de plata clorurada embutidos en soportes de plástico roscados a la estructura central del auricular. De ellos




Figura 2.20: Posición de los sensores del Emotiv EPOC en el sistema internacional 10-20

14 se utilizan como elementos de captura de datos mientras que dos se destinan a actuar como electrodos de referencia (P3 y P4 actúan como CMS (del inglés common mode sense) y tierra respectivamente (DRL del inglés driven right leg)). Se disponen dentro del sistema internacional 10-20 como se detalla en la Figura 2.20 cubriendo el lóbulo frontal del cerebro (posiciones AF3, AF4, F3, F4, F7 y F8) y el lóbulo temporal (FC5, FC6, T7 y T8). La actividad neutra del lóbulo occipital es capturada utilizando los electrodos O1 y O2.

Los datos cerebrales son capturados con una frecuencia de 2048Hz y se filtran y muestrean antes de su transmisión al PC. A éstos se añaden las muestras tomadas por el giroscopio que el dispositivo incluye, compuesto por dos acelerómetros que proporcionan información acerca del movimiento de la cabeza. Toda la información es transmitida de forma cifrada e inalámbrica en paquetes de 128 muestras por segundo desde el auricular a un receptor USB que se conecta a un ordenador.

En cuanto al filtrado, el sistema realiza un procesamiento de señal básico en el propio dispositivo que incluye un filtro paso bajo de los datos EEG con una frecuencia de corte de 85Hz, seguido por un filtrado paso alto con una frecuencia de corte de 0.16Hz. También incluye un filtro de Notch a las frecuencias de 50 y 60Hz para evitar las interferencias provenientes de armónicos de la señal de alimentación. Finalmente, el auricular incluye una batería recargable por USB con una duración en torno a las 12 horas.

Para disminuir la impedancia entre el cuero cabelludo y los electrodos, se aplica una solución salina a los mismos. Ésta es diferente del gel que normalmente utiliza en los cascos basados en electrodos húmedos y reduce drásticamente el tiempo de puesta en marcha del sistema.

Además del dispositivo en sí, Emotiv proporciona una aplicación llamada *Emotiv Con-*

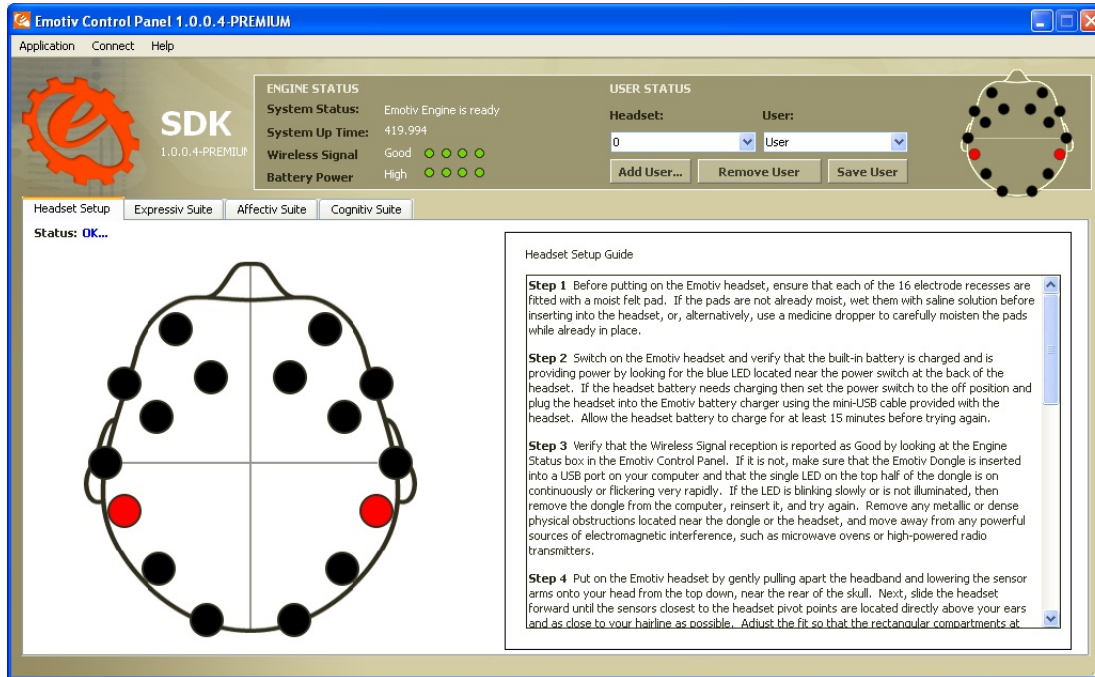


Figura 2.21: Panel de Control Emotiv EPOC

*trol Panel* (Figura 2.21) que permite visualizar la calidad de contacto de los electrodos basándose en una escala colores, el movimiento del giroscopio, la intensidad de la señal inalámbrica y la carga de batería. Este mismo software permite entrenar diferentes acciones y pensamientos divididos en diferentes suites (Expressiv, Affectiv y Cognitiv), aunque debido a la falta de transparencia respecto de los algoritmos, resulta difícil saber si únicamente se utilizan datos cerebrales o también derivados de los giroscopios disponibles en el eje X e Y.

1. Expressiv permite detectar varias expresiones faciales, que se representan en un avatar en la pantalla.
2. Affectiv se fundamenta en la detección de niveles de compromiso, frustración, meditación y excitación, estimando el estado emocional del usuario y representándolo en un gráfico.
3. Cognitiv posibilita la detección de ciertas acciones cognitivas a partir del movimiento de un cubo flotante. Entre ellas se encuentran empujar, tirar, rotar, elevar o mover hacia arriba, hacia abajo, a la izquierda y la derecha. Para el correcto funcionamiento de ésta es necesario un entrenamiento previo del sistema, dado que los patrones cerebrales para cada acción son dependientes del usuario. Como máximo se pueden controlar cuatro tareas de forma simultánea.



Dentro del mismo paquete, también se proporciona *Emokey*, que permite traducir los comandos detectados a mensajes estándar de Windows, como la pulsación de teclas o clicks de ratón.

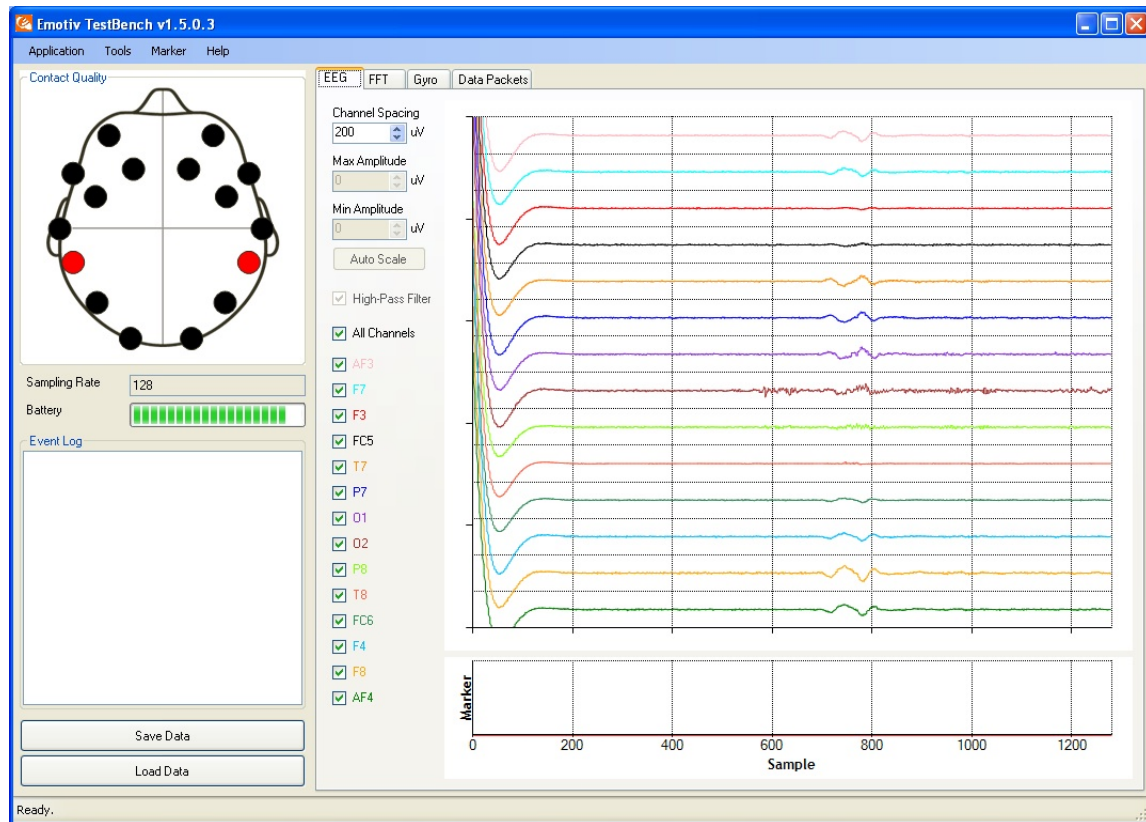


Figura 2.22: Test Bench Emotiv EPOC

Emotiv EPOC está siendo ampliamente utilizado por la comunidad científica como elemento de captura de datos dentro de sistemas de tipo BCI, tal y se detalla en los siguientes apartados. Para ello, existen fundamentalmente dos acercamientos: utilización de las tres diferentes suites que Emotiv proporciona a través del Panel de Control o utilización de los potenciales eléctricos leídos en el cuero cabelludo del usuario.

La ventaja de la primera de las opciones es que no resulta necesario desarrollar complicados algoritmos para utilizar el dispositivo. En este caso, el usuario puede empezar a utilizar la aplicación desde el momento en que conecta su auricular EEG sin necesidad de software o conocimientos adicionales, lo que facilita una primera toma de contacto con el dispositivo.

La segunda, no obstante, permite a los científicos un mayor control sobre la funcionalidad global del sistema BCI utilizando únicamente el Emotiv EPOC como un sistema de captura de datos. Cabe destacar que Emotiv proporciona una API que permite la interconexión del EPOC con aplicaciones desarrolladas por terceros, lo que posibilita comparar

su rendimiento con el de otros sistemas EEG profesionales, así como diferentes algoritmos de preprocesamiento y clasificación entre sí. Igualmente, a través de la Research Edition cabe la posibilidad de integrar el Emotiv EPOC con librerías de procesamiento de señales EEG como BCI2000, EEGLab y OpenVive [55]. Estas librerías proveen algoritmos de filtrado, preprocesamiento y clasificación ya programados que se pueden utilizar tanto para comprobar la calidad de los datos preliminares como para desarrollar aplicaciones de una forma más ágil.

Se presentan a continuación ejemplos de ambas aproximaciones disponibles en la literatura.

### 1. Control Panel - Expressiv Suite

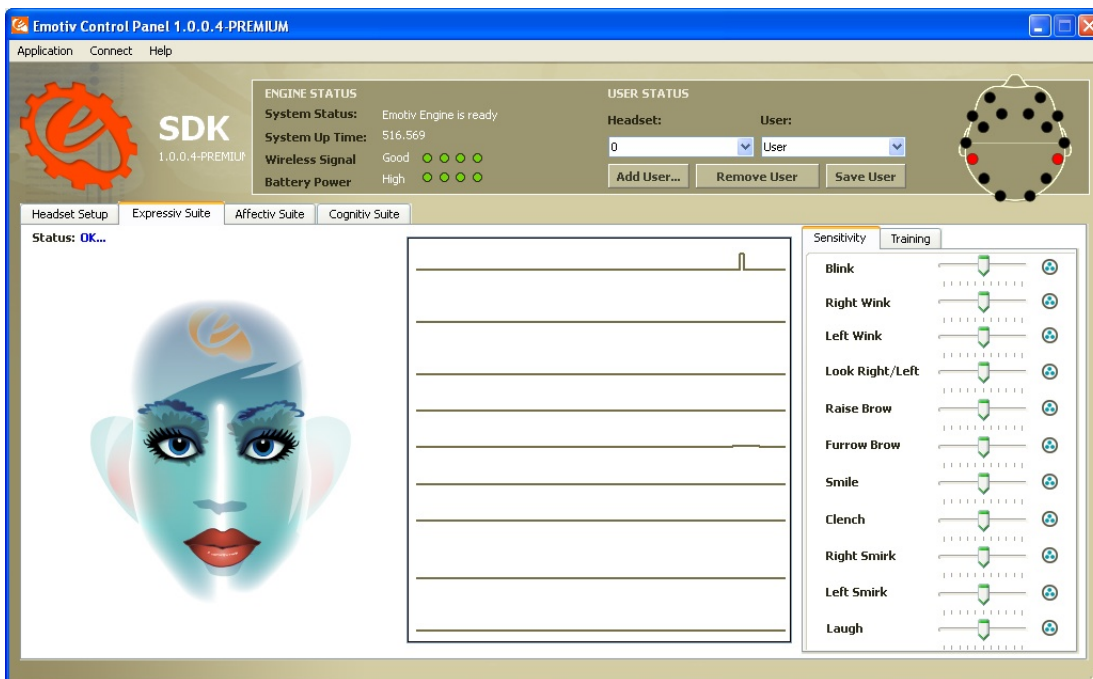


Figura 2.23: Panel de Control - Expressiv Suite

Dado que el Emotiv EPOC tiene 8 de los 14 sensores en posiciones pertenecientes al lóbulo frontal, es posible leer señales generadas por los músculos faciales y los ojos. La Expressiv Suite (llamada Facial Expressions en la última versión del Panel de Control Emotiv) es capaz de reconocer hasta 11 expresiones faciales de los usuarios, para ello interpreta las señales electromiográficas (EMG) capturadas (Figura 2.23), las cuales se considerarían artefactos o ruido en cualquier escenario BCI clásico. Como la estructura muscular facial es muy similar entre los usuarios el patrón que permite detectar estos datos es bastante genérico y rápido de controlar.

Por tanto el sistema funciona razonablemente bien sin entrenamiento previo, aunque con una pequeña latencia desde que se produce el movimiento hasta que el avatar



Tabla 2.3: Resumen de las características de las aplicaciones desarrolladas con Emotiv utilizando Expressiv Suite

Autor	Tipo de Aplicación	Características
Ranky, G.N. et al ([56])	Control de un robot	En concreto con el iARM de Exact Dynamics. Se encuentra un funcionamiento deficiente del sistema y se propone evitar su utilización conjunta.
Rojas, S. et al ([57])	Control de Menú y Teclado Virtual	Sistema capaz de distinguir entre 5 movimientos.
Krishnaswamy, K. et al ([58])	Evaluación de diferentes gestos	Evaluación de los gestos reir, guiñar, parpadear, mirar a la izquierda y la derecha. Como resultado, los tiempos de detección varían entre gestos y es necesario marcarlos mucho, por lo que la Expressiv Suite no parece recomendada para usuarios que hayan perdido capacidad gestual.
Scherer, R. et al ([59])	Integración con un juego de ordenador	Se asocian los diferentes gestos a macros de comandos en lugar de a una simple letra en el teclado, lo que permite aumentar la cantidad de acciones asociadas con un gesto.
Sinyukov, D. et al. ([60])	Control de una silla de ruedas	Se integra el EPOC en el control de una silla de ruedas, además de otros interfaces como uno de reconocimiento de voz o unas gafas Google Glass.
Nisar, H. et al. ([61])	Control de un coche LEGO	Se integra el EPOC con el control de un coche LEGO Mindstorms NXT utilizando Expressiv para los movimientos de izquierda, derecha, delante y detrás.
Shankar, S.S. et al. ([62])	Control de una aplicación CAD	Se integra el EPOC con el control de la aplicación Google SketchUp. Se mide el tiempo necesario para realizar figuras geométricas de dificultad creciente. También se utiliza la Cognitive Suite.
Ben Taher, F. et al ([63])	Control de una silla de ruedas	Se integra el EPOC en el control de una silla de ruedas en un sistema de control híbrido, utilizándose Expressiv Suite para enviar los comandos delante, detrás, izquierda y derecha. En una segunda fase se integra con Cognitiv Suite para realizar los mismos movimientos.
Madovs, B. et al. [64]	Control de una placa Arduino	Se utilizan expresiones faciales para crear señales de control que se asocian a pines específicos a habilitar en placas Arduino.
Alrajhi, W. et al. ([65])	Integración sistema Smart Home	Utilización de expresiones faciales para controlar tareas relacionadas con un sistema Smart Home. Se comparan resultados obtenidos utilizando Expressiv (Facial Expressions) y Cognitiv suites. Expressiv se considera más sencilla de utilizar debido al tiempo de entrenamiento y la facilidad para generar el pensamiento.

lo muestra en la pantalla. Del mismo modo, existe la posibilidad de transformar tales gestos en señales de control y relacionar las mismas con comandos a través de la funcionalidades provistas por *Emokey*. Como resulta evidente, aunque no sea imperativo, la realización de un entrenamiento redundante en una mejor tasa de acierto en el uso de la funcionalidad.

Como se puede desprender de la Tabla 2.3 el grueso de la investigación científica realizada se aplica al gobierno de dispositivos, a través de la conversión de la actividad gestual del usuario a comandos de control.

## 2. Control Panel - Affectiv Suite

La Affectiv Suite (Figura 2.24) provee de una medida entre 0 y 1 del nivel emocional del usuario representado en un gráfico. Permite detectar los niveles de excitación a

corto y largo plazo, frustración, meditación y concentración. Este tipo de estados no se puede entrenar, sino se que detectan basándose en las características de la señal EEG relacionadas con las emociones.

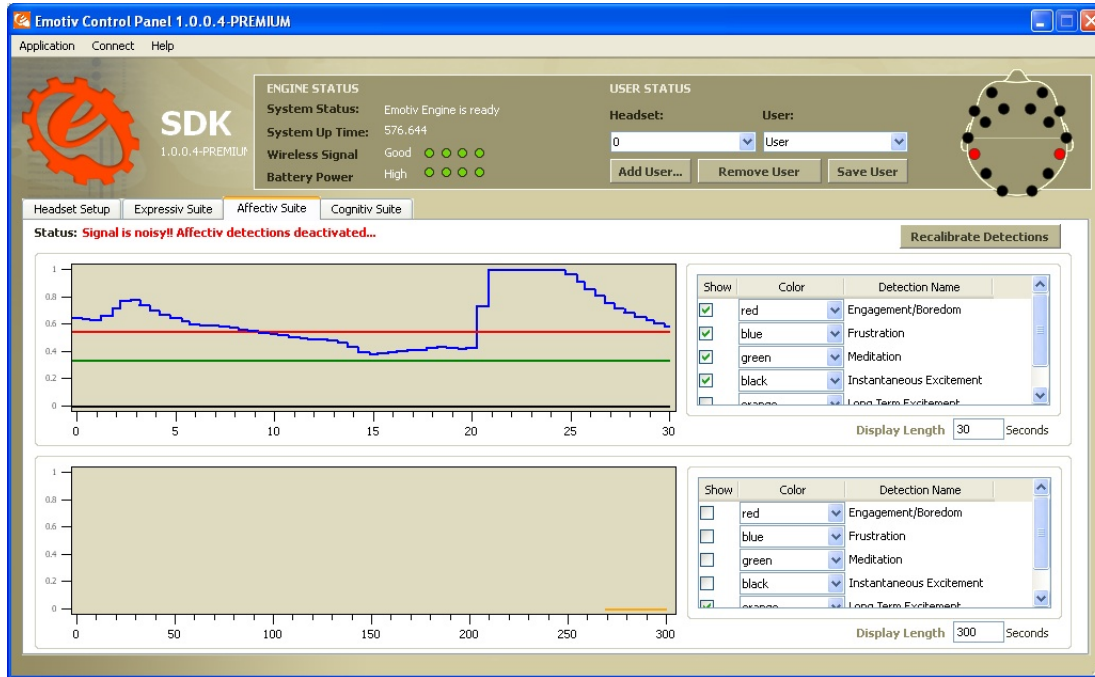


Figura 2.24: Panel de Control - Affectiv Suite

Existen varias líneas de investigación que van desde la evaluación de la propia precisión de la suite con respecto a la respuesta del usuario basándose en cuestionarios de referencia ([66, 67]), como su uso en sistemas para mostrar las emociones en un chat ([68]), aplicaciones relacionadas con los estudios de mercado ([69]), mejora de la atención de los usuarios a los contenidos ([70]) u otras relacionadas con la evaluación subconsciente de películas, lugares, juegos o modelos de formación ([71, 55, 72, 73, 74, 75]).

Como se puede apreciar, el área de evaluación subconsciente es de especial interés ya que permite determinar las preferencias del sujeto evitando las desviaciones introducidas en los cuestionarios.

También se aplica la funcionalidad disponible en el control de parámetros relacionados con el estado de ánimo durante el control de elementos externos, tales como sillas de ruedas ([76]) y exoesqueletos ([77]). De este modo, los sistemas BCI facilitan la adopción de este tipo de elementos haciendo más amigable su operación.

### 3. Control Panel - Cognitiv Suite

La Cognitiv Suite se basa en la voluntad consciente del usuario de realizar un movimiento a partir de un pequeño avatar en forma de cubo en suspensión. Éste

Tabla 2.4: Resumen de las características de las aplicaciones desarrolladas con Emotiv utilizando Affectiv Suite

Autor	Tipo de Aplicación	Características
Cernea, D. et al ([66])	Evaluación Expresiv y Affectiv Suites	Comparación con resultados extraídos de cuestionarios estándar. Se encuentra una diferencia entre los cuestionarios escritos y los resultados obtenidos con Emotiv entre el 13.6 % y el 37 %.
Seigneur, J ([69])	Medición de la satisfacción	Se propone un modelo basado en la satisfacción del usuario medida con Emotiv EPOC ante ciertos productos o servicios para definir el precio que éste ha de pagar por los mismos. Se integra con un sistema GPS para determinar los lugares que generan o no satisfacción en el usuario en un experimento de una excursión.
Hamdi, H. et al ([67])	Evaluación Expresiv y Affectiv Suites	Evaluación de los resultados de Emotiv para un problema clásico basado en el modelo de Ekman, utilizando un conjunto de imágenes basadas en el IAPS. Se muestra gran variación entre usuarios y sujetos para las diferentes emociones pero los resultados son congruentes con los de Ekman.
Shirazi, A.S. ([71])	Medición de los niveles de entusiasmo	Anotación de los niveles de entusiasmo en las escenas de un vídeo. Los resultados coinciden con los obtenidos de los mismos usuarios a través de sus cuestionarios.
Mavros, P. ([55])	Medición del estado de ánimo	Se graban los estados del usuario al ver ciertos edificios y se experimenta en un modelo real por las calles del centro de Edimburgo.
Kuber, R. et al ([68])	Integración con una aplicación de IM	Se mejora la experiencia de usuario, se reduce el número de palabras que se intercambian y se aumentan las relacionadas con su estado emocional.
Fattouh, A. et al ([76])	Control silla de ruedas	Se detecta el estado de ánimo del usuario. Cuando éste se encuentra frustrado, la silla se para y espera un nuevo comando. Los comandos proporcionando dirección se recogen desde Cognitive Suite.
Guo, S. et al ([77])	Control de un exoesqueleto para un brazo	Utiliza el estado de concentración del usuario para determinar si éste desea comenzar, parar, mantener o finalizar el proceso de entrenamiento.
Verkijika, S.F. et al ([72])	Medición del nivel de ansiedad	Medición del nivel de ansiedad de 36 estudiantes de entre 10 y 16 años ante la realización de problemas matemáticos. Integración con un juego y demostración de que la ansiedad ante problemas matemáticos puede disminuirse.
Ghergulescu, I. et al ([73])	Medición del nivel de atención	Se utiliza Affective suite para grabar el nivel de atención de los usuarios mientras juegan. De esta forma se evalúa el nivel de inmersión y, a su vez, la validez de la plataforma creada.
Ghali, R. et al. ([74])	Extracción percepción usuario completando un juego científico	Se toman medidas de los niveles de excitación a corto y largo plazo, meditación, frustración y aburrimiento. Estos datos se utilizan junto con otros obtenidos de la dilatación de la pupila y la expresión facial del usuario para determinar la dificultad que el usuario encuentra en el juego
Tilley, S. et al. ([75])	Medición de la percepción del usuario ante diferentes entornos caminando	El estudio se basa en la grabación de los estados registrados por Emotiv EPOC mientras personas mayores caminan por la ciudad de Edimburgo siguiendo rutas pre-establecidas de alrededor de 15 minutos en las que pasan del stress de una zona muy transitada a un parque y viceversa.
Moldovan, A.N. et al. ([70])	Medición de la percepción del usuario	Se utiliza el EPOC para capturar el estado de atención de los sujetos en el proceso de visualizar contenidos de aprendizaje en dispositivos móviles: teléfono móvil vs tablet.

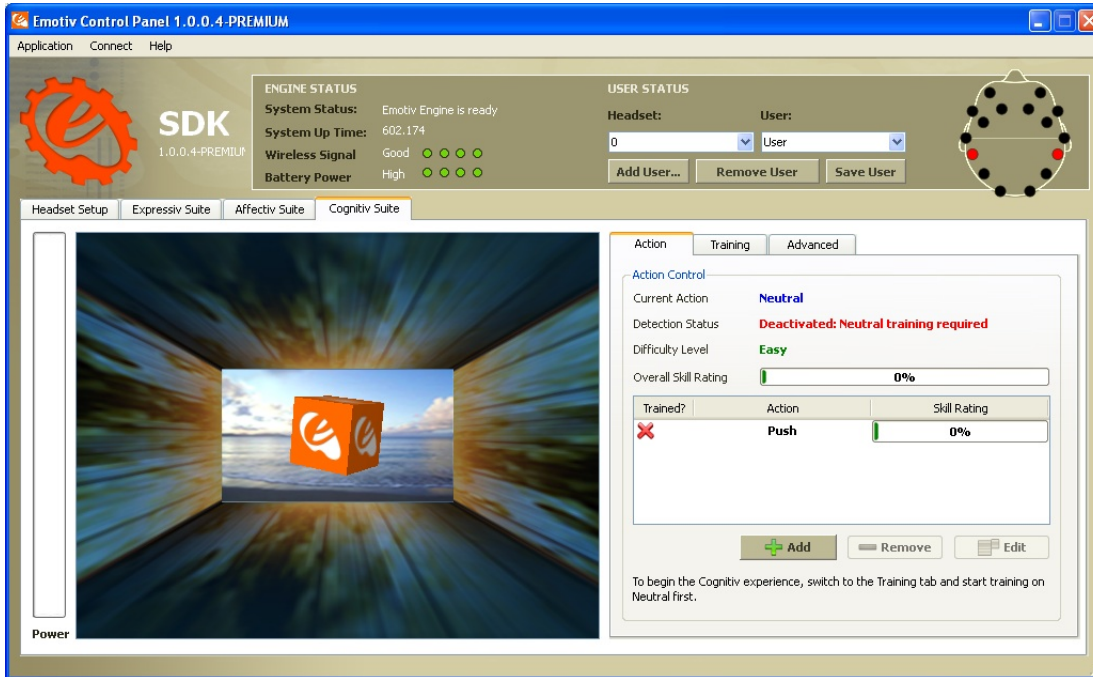


Figura 2.25: Panel de Control - Cognitiv Suite

puede realizar hasta trece movimientos diferentes de los cuales sólo cuatro se pueden distinguir simultáneamente. De estos movimientos seis son direccionales (izquierda, derecha, arriba, abajo, empujar, tirar), seis son rotatorios (rotación horaria y antihoraria, rotar izquierda y derecha, mecercer hacia delante y hacia atrás) y uno se asocia con la visualización (desaparecer). En la Figura 2.25 se puede apreciar el entorno gráfico de la misma.

Un requisito fundamental en la utilización de esta suite es la necesidad de realizar un entrenamiento previo. Éste permite al Panel de Control grabar la actividad cerebral y definir tanto un estado de reposo o neutro como encontrar el patrón asociado a cada acción, de forma que se puedan utilizar esos mismos modelos posteriormente para determinar el pensamiento del usuario. Cabe destacar que los datos cerebrales son diferentes para cada sujeto e incluso la literatura muestra que se obtienen diferentes resultados en momentos distintos del día, dependiendo del cansancio, atención y concentración.

El entrenamiento consiste en la grabación de los patrones cerebrales en intervalos de 8 segundos. Estos periodos de tiempo son iguales para el estado de reposo o neutro, aunque también es posible grabar una sesión en estado neutro de 30 segundos. Hasta que no se han completado tres sesiones de entrenamiento no se muestra tasa de acierto alguna para la actividad seleccionada en el panel de control.

La recomendación de Emotiv en este aspecto es comenzar entrenando un número

Tabla 2.5: Resumen de las características de las aplicaciones desarrolladas con Emotiv utilizando Cognitiv Suite

Autor	Tipo de Aplicación	Características
Thobbi, A. et al. ([78])	Control remoto de un humanoide	Los usuarios entrenan tres acciones diferentes: mover hacia la izquierda, mover hacia delante y mantener quieto en el marco del control de un robot humanoide. La tasa de acierto conseguida se eleva al 78,35 %.
Vourvopoulos, A. et al. ([79])	Control de un robot	Construcción de un sistema de control BCI para un robot utilizando componentes estándar. Se entrenan 4 Movimientos: Cognitiv Suite para delante y detrás y Expresiv Suite para izquierda y derecha. Los resultados presentados en la fase de experimentación no se relacionan con Emotiv.
Taylor, G.S et al ([80])	Evaluación Cognitiv Suite	Evaluación de Cognitiv Suite realizada a partir de una muestra 57 usuarios evaluando dos estados opuestos aleatoriamente. Se evalúan la tasa de éxito y la de aparición de falsos positivos.
Sepúlveda, G et al. ([81])	Control de un robot virtual	Utiliza Cognitiv Suite generar el mapa con la ruta del desplazamiento del robot, que se transforma en movimiento del mismo una plataforma virtual a partir de un modelo cinemático.
Luo, Y et al ([82])	Control posicionador de precisión	Se consigue entrenar un sistema BCI basado en Emotiv EPOC para controlar el movimiento de un posicionador de precisión. Primero en un entorno virtual y después en uno real.
Vourvopoulos, A. et al. ([83])	Integración con plataforma virtual	Se integra con una plataforma de realidad virtual que detalla la ciudad de Roma. No ofrece resultados cuantitativos pero ofrece pistas sobre la respuesta de usuarios noveles ante el uso del Emotiv EPOC.
Webb, J. et al ([84])	Prótesis rehabilitadora	Se integra Emotiv EPOC con una prótesis rehabilitadora. Se realizan pruebas con 4 sujetos que no tienen ninguna lesión cerebral y que consigue un acierto total en el control de la prótesis desde la segunda sesión.
Chowdhury, P. et al ([85])	Control de un robot	Se integra Emotiv EPOC con un robot y se realizan pruebas con una población entre 14 y 30 años incluyendo un paciente impedido. Se evalúa la tasa de acierto por franjas de edad.
Swee, S.K. et al. ([86])	Control de una silla de ruedas	Se utiliza Emotiv EPOC como elemento de control de una silla de ruedas y se compara el acierto utilizando Cognitiv con el conseguido por el método propuesto.
Barresi, G. et al ([87])	Activación selección teclado virtual	Se utiliza el nivel de concentración en lugar del patrón de movimiento en sí. Esto permite, cuando el patrón se encuentra por encima del 70 %, seleccionar el carácter.
Schiatti, L. et al ([88])	Control rigidez posición brazo articulado	Se integra un Emotiv EPOC en el control de un brazo robótico fundamentalmente dirigido por un sistema de control visual. Se utiliza el pensamiento de Empujar para determinar la rigidez en la posición del brazo aportando un nuevo grado de libertad al usuario.
Shah, B.C. ([89])	Control de un robot humanoide remoto	Realmente se utiliza el Emotiv EPOC para controlar una plataforma en la que se simula el control de la trayectoria de un robot humanoide de forma remota. Se describen el resto de los componentes del sistema y cómo se integran, pero no se realiza ninguna prueba real.
Tabernig, C.B. et al ([90])	Mejora en técnicas de rehabilitación	Evaluación del efecto de la rehabilitación basado en un sistema BCI utilizando Emotiv EPOC y de estimulación eléctrica muscular (FES). Se capturan las ondas cerebrales del sujeto cuando se imagina el movimiento de la mano paralizada para coger un vaso frente a él. El sistema FES se utiliza para contraer la muñeca y los músculos extensores del miembro más afectado.

reducido de estados hasta conseguir una tasa de acierto relevante antes de continuar añadiendo más. En [81] se determina que después de una sesión de 60 minutos es posible controlar al menos dos opciones, aumentando el número de sesiones de entrenamiento a medida que se aumenta el número de actividades.

La experiencia en el uso de Emotiv adquirida pone de manifiesto que no cualquier pensamiento entrena cualquier acción. Es decir, cuando se entrena el movimiento hacia la izquierda pensamientos que no sean éste no consiguen aumentar la tasa de acierto del sistema. Ésto hace dudar sobre si realmente es el usuario quien entrena el sistema o el Emotiv EPOC el que determina cómo ha de pensar el usuario. En cualquier caso, si bien entrenar dos estados es relativamente sencillo, el aumento del número de acciones implica un esfuerzo de entrenamiento importante antes de poder dominarlos.



Figura 2.26: Prótesis de rehabilitación integrada con Emotiv EPOC [84]

Entre las publicaciones disponibles que han utilizado el Emotiv EPOC junto con la Cognitive suite se pueden encontrar evaluaciones de la precisión de la misma [80], aunque la comunidad científica se ha centrado en utilizar las acciones cognitivas disponibles para integrar el EPOC con sistemas de control de todo tipo, ya sea en plataformas virtuales ([81, 82, 83, 89]) o sistemas de control reales, incluyendo robots ([78, 79, 85]), prótesis rehabilitadoras ([84, 90]) o sillas de ruedas ([86]). Como nota, también se pueden encontrar estudios donde se utiliza el campo en el que el panel de control ofrece el nivel de la concentración del usuario durante la realización de cada determinada acción ([87]). Éstas y alguna otra aplicación se incluyen en la Tabla 2.5.

#### 4. Emotiv EPOC en otras aplicaciones BCI

Dependiendo del tipo de licencia de Emotiv que se posea es posible acceder a los potenciales eléctricos leídos en el cuero cabelludo del usuario en tiempo real, utilizando el Emotiv EPOC como un sistema de captura de datos EEG tradicional. En estos casos el abanico de opciones disponible se amplía sensiblemente, puesto que no existe más barrera en términos de funcionalidad que la imaginación y capacidad del investigador.



Figura 2.27: Integración de Emotiv EPOC con un teléfono móvil. NeuroPhone [92]

Este apartado se dedica a enumerar algunos de dichos trabajos, cuyo alcance incluye estudios de mejora de la precisión de los sistemas BCI integrando Emotiv EPOC, ya sea a través de la optimización en la detección de los artefactos [91], la evaluación de métodos de procesamiento y clasificación ([93, 27, 102]) o el análisis de paradigmas BCI clásicos como SSVEP (precisión del  $95,83 \pm 3,59\%$  en [113]), P300 ([37, 92, 95]) o motor imagery ([100, 101]).

También se pueden encontrar ejemplos donde Emotiv EPOC se integra en diferentes tipos de sistemas BCI que, de uno y otro modo, se basan en los paradigmas anteriores. Entre ellos juegos ([114]), sistemas de selección de contactos en la agenda del teléfono móvil ([92]), activación de funciones auxiliares en un vehículo [96], sistemas de asistencia para el control del PC [97], control de sillas de ruedas ([98]) e integración con prótesis rehabilitadoras ([94, 99, 115]).

Igualmente, existen otras aplicaciones donde se utiliza Emotiv EPOC para evaluar la seguridad de los sistemas BCI [95] o se pretende crear bases de datos centralizadas de usuarios a partir del uso de la nube ([103]).

Finalmente, en los últimos dos años ha habido una importante evolución de los estudios que utilizan Emotiv EPOC como una herramienta fiable en la detección

Tabla 2.6: Resumen de las características de las aplicaciones desarrolladas con Emotiv sin utilizar algoritmos disponibles en el Panel de Control

Autor	Tipo de Aplicación	Características
O'Regan, S. et al ([91])	Captura de datos	Se utiliza Emotiv EPOC para obtener resultados preliminares de 4 usuarios antes de acometer el estudio con una base de usuarios más amplia, que se realiza con un equipo <i>Neuroscan</i> de 64 electrodos.
Rosas-Cholula, G. et al ([37])	Caracterización de la señal P300	Evaluación de la calidad en la detección de la señal P300 utilizando Emotiv EPOC como dispositivo de captura, DWV como método de preprocesado e ICA como algoritmo de clasificación. El estudio concluye que se pueden detectar los ritmos P300 utilizando Emotiv EPOC.
Campbell, A.T. et al ([92])	Control de la agenda de un móvil	Se utiliza un Emotiv EPOC y un paradigma P300 para distinguir la persona a llamar entre 6 presentadas en la pantalla. El preprocesamiento y la clasificación se implementan en el teléfono.
Choudhury, S. ([93])	Comparación algoritmos de clasificación	Se comparan resultados de SVM con GP. GP ofrece mejores resultados para el conjunto de entrenamiento mientras que SVM lo hace para el de test.
Fok, S et al ([94])	Prótesis de rehabilitación	Se integra el Emotiv EPOC en un sistema para el control de una prótesis que abre y cierra la mano.
Martinovic, I. et al ([95])	Captura de Datos	Se evalúa la seguridad de los sistemas BCI basados en P300 en base a la posibilidad de que el usuario ofrezca información privada de forma involuntaria.
Cernea, D. et al ([96])	Control de sistemas auxiliares	Aplicación de EEG para el control de sistemas auxiliares en un coche. Se integra el Emotiv EPOC con un simulador de conducción y se realizan diferentes pruebas incrementando el número de tareas a controlar con el cerebro. Se comprueba que hay un límite máximo en el número de acciones que se pueden controlar sin afectar a la seguridad de la conducción.
Soman, S. et al ([97])	Ratón virtual	Creación de un ratón virtual para el PC.
Carrino, F et al ([98])	Control de una silla de ruedas	El paradigma utilizado es con dos estados (izquierda y derecha). Se consigue una tasa de acierto del 67,5 % pero el usuario encuentra dificultoso dirigir la silla de ruedas debido a los falsos positivos. La precisión con un equipo profesional asciende hasta el 91 %.
Holmes, C.D. et al ([99])	Prótesis de rehabilitación	Se construye una prótesis rehabilitatoria a partir de componentes comerciales integrando Emotiv EPOC.
Prince, D. et al ([100])	Evaluación precisión Emotiv	Se seleccionan mediante inspección de los datos en raw una serie de canales y se utiliza LDA para identificar la acción que el usuario está realizando en un escenario con dos estados: neutro-izquierda y neutro-derecha. Se alcanza una precisión del 100 % para los canales preseleccionados.
Fakhruzzaman, M.N. et al ([101])	Evaluación Emotiv EPOC en un escenario de motor imagery	La evaluación consiste en distinguir entre movimiento de la mano izquierda o del pie derecho. También se planean escenarios híbridos. El sistema tiene feedback y muestra una flecha. Emotiv puede distinguir correctamente los escenarios de imaginación pero no los híbridos.
Shedeed, H.A. et al. ([102])	Evaluación de diferentes métodos de extracción	Se utilizan datos capturados con Emotiv para comparar la diferencia entre las técnicas de extracción de características mediante Transformada Wavelet, Transformada Rápida de Fourier, Análisis de Componentes Principales y Auto Regresión, con datos normalizados y no normalizados.
Petrov, B.B. et al. ([103])	Lectura datos EEG	Lectura de datos EEG de pacientes e integración del Emotiv EPOC con una placa de tipo Raspberry Pi 3 para el envío de datos a un sistema central de forma automática.



Tabla 2.7: Diferentes aplicaciones desarrolladas utilizando Emotiv EPOC publicadas en revistas de investigación desde 2017

Autor	Tipo de Aplicación	Características
Hsu, W.Y. ([104])	Estudios de Mercado	Emotiv EPOC capturó la reacción 60 usuarios evaluando el empaquetado de ciertos productos a partir de escenarios de 40 segundos donde se mostraron dos opciones y se grabaron datos después utilizados para crear un clasificador basado en un perceptrón multicapa que finalmente fue capaz de definir la preferencia cerebral del sujeto por la opción seleccionada.
Shin, J. et al ([105])	Integración con otros dispositivos	Se utiliza el procedimiento mostrado en [106] y se utiliza la malla EasyCap para integrar Emotiv EPOC con un dispositivo de bajo coste de tipo NIRS. Se distinguen tres tareas, asignación entre palabra e imagen, operación aritmética y reposo. Los resultados del sistema conjunto son un 6,2% y un 2,5% mejores que los resultados del Emotiv EPOC o sistema NIRSport NIRx por separado.
Bodranghien F. C. A. A. ([107])	Análisis de datos EEG	Se utiliza Emotiv EPOC para capturar las señales EEG producidas en el cerebro al pensar en movimiento de los dedos de la mano derecha e izquierda con el objetivo de determinar el efecto de la electroestimulación anodal transcraneal de corriente directa aplicada al cerebelo previamente.
Haider, S.K. et al ([108])	Integración con otros dispositivos	Se utiliza Emotiv EPOC para grabar señales cerebrales basadas en el paradigma P300 con el objetivo de detectar la veracidad de la respuesta del usuario con dos clases: verdad y mentira. A partir de ahí se integra en primer lugar con Matlab y después con una placa FPGA de Xilinx donde se repite toda la lógica. La máquina de la verdad construida muestra un acierto del 85%.
Li, R. et al ([109])	Análisis de datos EEG	Se presenta un nuevo tipo de SSVEP llamado Scene Graph SS-VEP y para probar su capacidad se realiza un experimento con seis usuarios en los que éstos utilizan un sistema BCI que utiliza Emotiv EPOC como elemento de captura de datos e integra un brazo articulado. La nueva metodología alcanzó el 96,2% de acierto utilizando periodos de 4 segundos. Únicamente se utilizaron las posiciones O1 y O2.
Kilmarx, J. et al ([110])	Integración con otros dispositivos	Se utiliza Emotiv EPOC como dispositivo de captura de datos para obtener las señales entre 0.16 y 1 Hz para que codifican la información kinestética necesaria para operar un brazo robótico de seis grados de libertad. Asimismo, también se utiliza para capturar datos en la etapa de entrenamiento basada en el movimiento de un cursor en la pantalla.
Saini, R. et al ([111])	Análisis de datos EEG	Se combinan la firma con los patrones cerebrales generados al firmar para mejorar los sistemas de identificación del sujeto utilizando un modelo multimodal. Emotiv EPOC se utiliza en la fase de captura de datos, que se procesan de forma off-line.
Kotowski, K. et al ([112])	Análisis de datos EEG	Se plantea una mejora de bajo coste a Emotiv EPOC+ para marcar los eventos mostrados para escenarios ERP. El objetivo es facilitar la búsqueda de la señal cerebral que se produce a partir de ellos. Se valida la solución midiendo la componente de negatividad posterior temprana (EPN del inglés early posterior negativity) modulada por las expresiones faciales del experimento.

de señales cerebrales para su integración tanto en sistemas finales ([105, 108, 110]) como en estudios que utilizan los datos EEG para establecer resultados en otras áreas ([104, 107, 109, 111]). Entre las múltiples publicaciones existentes se han priorizado aquéllas que han aparecido en revistas internacionales a los congresos con el objetivo



Figura 2.28: Silla de ruedas controlada utilizando Emotiv EPOC [98]

de mantener una tabla de reducidas dimensiones (Tabla 2.7).

#### 5. Evaluación de la calidad de la señal capturada

Dada la diferencia de coste entre los sistemas de adquisición EEG médicos o de investigación y el Emotiv EPOC se está desarrollando un nuevo cuerpo de conocimiento que compara las prestaciones de ambos tipos de dispositivo. El objetivo es determinar en qué aplicaciones los sistemas EEG de bajo coste pueden sustituir con garantías a los de ámbito profesional.

Para ésto, la mayoría de las investigaciones se han centrado en realizar un determinado experimento y comparar los resultados. Atendiendo a los dispositivos profesionales utilizados en la comparación, existen diferentes alternativas. Entre ellas destacan las comparaciones con g.USBamp ([113]), actiCap ([114, 115]), BrainAmp ([27]), ANT ([116]), Biosemi ([117]) o Neuroscan ([118, 119]).

Existen fundamentalmente tres escenarios para los que se evalúan los diferentes sistemas: potenciales visualmente evocados de estado estatico (SSVEP del inglés Static-State Visually Evoked Potentials), señales de tipo P300 e imaginación de movimiento (motor imagery).

- a) SSVEP. Los estudios muestran que Emotiv EPOC es una solución viable para el reconocimiento de este tipo de señales. Cuando se compara la forma de los potenciales capturados por Emotiv EPOC y un dispositivo profesional se puede observar una gran similitud entre los mismos, tal y como mostraron De Lissa

et al. [119] o Badcock et al. ([118]). En el primero de los estudios se analizó el paradigma N170, que elicitaba una señal cerebral cuando se reconocía una cara. En este caso se analizaron las diferencias entre las formas de onda capturadas en las posiciones T7 y T8 utilizando un EPOC y Neuroscan, y se concluyó que tienen una correlación alta. Badcock et al. superpusieron el sistema Neuroscan y el Emotiv EPOC sobre el mismo usuario y compararon los canales de Neuroscan (F3 y F4) y Emotiv EPOC (AF3 y AF4). El experimento mostró una buena correspondencia entre las señales de los canales adyacentes comparados (F3 vs AF3 y F4 vs AF4). No obstante, apuntaron como desventaja que el número de muestras no estadísticamente representativas y la latencia en la detección de la señal fueron mayores para Emotiv EPOC.

Otros investigadores como Liu et al. ([113]) también han comparado dispositivos profesionales con el Emotiv EPOC. En este caso, la mayor diferencia está en las posiciones de referencia, dado que pertenecen a la parte posterior del cerebro (P8, P7, O1 y O2). El dispositivo profesional fue un g.USBamp y se realizaron dos experimentos, uno off-line y otro on-line. En el primero, Emotiv EPOC alcanzó un acierto medio del 82,99 % mientras que con el g.USBamp se consiguió un 94,79 %. Después estos investigadores incluyeron un experimento on-line en el que la precisión conseguida con Emotiv ascendió  $95,83 \pm 3,59$  %.

Por último, en [114] se utilizaron todos los sensores tanto del Emotiv EPOC como de un sistema actiCap de 8 posiciones. El procesamiento en este caso se realizó en el dominio del tiempo y se estableció la relación entre la tasa de acierto y el tamaño de la ventana de procesamiento. Se puede observar como el actiCap alcanzó una mayor precisión con ventanas reducidas de datos, pero esta diferencia disminuyó hasta un valor en torno al 5 % cuando el tamaño de ventana llegó a los 2 s. También se puede observar que con Emotiv EPOC alcanzó un acierto superior al 80 % a partir de un tamaño de ventana de 1,5 s.

- b) P300. Al igual que en el ejemplo anterior, el resultado de las comparaciones permite concluir que Emotiv EPOC es una solución viable para la detección de la señal P300. En este caso se encontró en [116] que, a pesar de que el sistema ANT permite una mayor precisión en la detección, la diferencia no es significativamente alta (entre 1,2 y 3,4 %) y que la tasa de acierto global se situó en el rango del 80 %. Por su parte, Ries et al. ([117]) identificaron un mayor número de artefactos en la señal capturada con EPOC y una latencia mayor. En este caso sólo se pudo distinguir la señal P300 capturada con Emotiv EPOC de forma visual después de realizar tareas de filtrado y preprocesado, mientras que fue perfectamente reconocible en los datos capturados con el sistema Biosemi.
- c) Imaginación de movimiento. El escenario clásico consiste en distinguir entre dos estados, normalmente mover la mano izquierda o derecha, y es el que supone un mayor reto atendiendo a los resultados publicados. Como AlZubi et al. mostraron en ([27]), la precisión conseguida para un sistema EEG profesional modelo *BrainAmp* fue del 58 %, mientras que para el EPOC se alcanzó un 53 %. Una variante del mismo trabajo se propuso en [115] y consistió en pensar en cerrar la

mano al ver una flecha apuntando a la derecha, con el objetivo de controlar una prótesis rehabilitadora. En este caso se evaluó el rendimiento utilizando todos los sensores tanto de un sistema de captura de datos actiCAP V-Amp como de un Emotiv EPOC+. En este estudio sí que apareció una diferencia considerable entre los resultados con una tasa de acierto del 82.5 % en los datos capturados con actiCAP y únicamente un 65 % para Emotiv EPOC.

Atendiendo al análisis anterior, resulta evidente la necesidad de profundizar y mejorar los niveles de acierto relacionados con la imaginación del movimiento utilizando sistemas de adquisición de señales EEG de bajo coste, dado el bajo rendimiento alcanzado en los resultados publicados hasta la fecha.

Tabla 2.8: Publicaciones evaluando la calidad de los datos capturados con Emotiv EPOC tomando como referencia los obtenidos por equipos EEG de investigación

Autor	Tipo de Aplicación	Características
AlZubi, H.S. et al ([27])	Análisis de métodos de extracción de características	Comparación de los resultados con <i>BrainAmp</i> . - Mejor resultado BrainAmp: 53 %. - Mejor resultado Emotiv EPOC: 58 %.
Liu, Y. et al ([113])	Análisis de Prestaciones	Paradigma: SSVEP. - Mejor resultado <i>g.USBamp</i> : 94.79 %. - Mejor resultado Emotiv EPOC: 82.99 %.
Vliet, M. et al ([114])	Análisis de Prestaciones	Paradigma: SSVEP a través del control de un juego. - Mejor resultado <i>ActiCap</i> : 88 % aprox. - Mejor resultado Emotiv EPOC: 82 % aprox.
Duvinage, M. et al ([116])	Análisis de Prestaciones	Paradigma: P300. - Mejor resultado ANT: 91 % aprox. - Mejor resultado Emotiv EPOC: 90 % aprox.
Badcock, N.A. et al ([118])	Comparación Señales	Paradigma: P1, N1, P2, N2, P3, MMN. Comparando posiciones Neuroscan F3 y F4 con EPOC AF3 y AF4. Alta correlación entre las señales capturadas (entre 0.82 y 0.95). Señal EPOC muestra una precisión temporal menor y una mayor cantidad de ruido.
De Lissa, P. et al ([119])	Comparación Señales	Paradigma: N170. Comparando posiciones P7, P8 y VPP - F3 & F4 mediante el uso simultáneo de Neuroscan y EPOC. Correlación mínima encontrada entre las señales de los sensores en la misma posición igual al 79 %.
Ries, J. et al ([117])	Comparación Señales	Paradigma: P300. EPOC muestra una precisión temporal menor y una mayor cantidad de ruido. - Mejor resultado Biosemi: 93 % aprox. - Mejor resultado Emotiv EPOC: 86 % aprox.
McConnell, A.C. et al ([115])	Análisis de Prestaciones	Paradigma: motor imagery a través del control de una prótesis rehabilitadora. - Mejor resultado ActiCap (V-Amp e EasyCap): 82.50 %. - Mejor resultado Emotiv EPOC: 65 %.

### 2.6.2. Emotiv EPOC - EasyCap

Una de las mayores desventajas del Emotiv EPOC en su aplicación al ámbito de la investigación estriba en la rigidez de la ubicación de los sensores. Éstos se encuentran en posiciones fijas delimitadas por la estructura plástica en la que se enroscan, por lo que las únicas variaciones posibles son aquellas en las que se varía completamente la ubicación del dispositivo y por ende, de todos los sensores.

Además, las posiciones de los electrodos C3 y C4 son ampliamente reconocidas en la literatura como las más adecuadas para la detección de los fenómenos ERD/ERS que

aparecen asociados a la imaginación del movimiento. Sin embargo, estas áreas no se encuentran cubiertas por ninguno de los sensores de Emotiv EPOC. En el mejor de los casos, lo que se recomienda desde Emotiv es ubicar el EPOC inclinado hacia atrás de modo que los sensores en las posiciones F3 y F4 se acerquen lo máximo posible a las localizaciones objetivo. Sin embargo, ésto no se consideró una aproximación científica válida dada la variabilidad que el operador ubicando el casco introduce al sistema. Por tanto, para obtener datos de tales posiciones se ha utilizado un sistema EEG híbrido construido siguiendo el trabajo realizado por el profesor Debener y su equipo en [106] (Figura 2.29).




Figura 2.29: Usuario utilizando el sistema híbrido Emotiv EPOC EasyCap

En dicho artículo, y con el objetivo de evaluar la señal P300 capturada en un entorno real, se presenta una integración entre el Emotiv EPOC y una malla profesional de tipo EasyCap ([120]). Además, se documentan como beneficios de esta aproximación la reducción en el factor de forma, la posibilidad de integración con sensores de mayor calidad y la flexibilidad en la ubicación de los mismos.

Cabe destacar que Emotiv EPOC EasyCap sólo mantiene la unidad de procesamiento y comunicaciones original. Por tanto, los datos capturados se procesan de la misma forma que en un EPOC convencional y se transmiten utilizando tecnología Bluetooth a la misma llave USB. No obstante, la tecnología de los sensores es totalmente diferente. Básicamente, éstos pasan a ser sensores convencionales que requieren la utilización de gel para aumentar la conductividad entre los mismos y cuero cabelludo. Asimismo, es necesario un nuevo cableado entre éstos y la unidad de procesamiento.

En esta tesis doctoral se ha utilizado la implementación del modelo anterior presentada en [121].

Cabe también destacar el muy reciente lanzamiento por parte de Emotiv de un sistema de exactamente estas características, integrando una malla de tipo EasyCap con una densidad de 32 electrodos que, dependiendo de si son salinos o de gel, se ofertan con un coste superior a los \$1.600 [52].

## 2.7. Datos BCI Competition

Ante el creciente interés por los sistemas BCI dentro de la comunidad científica, varios de los equipos precursores de este área tomaron la decisión de organizar concursos donde los diferentes grupos de investigación pudieran evaluar la precisión de sus algoritmos de procesamiento y clasificación. Para ello se hicieron públicos una serie de conjuntos de datos relacionados con problemas específicos dentro del dominio de los sistemas de control BCI. Se organizaron cuatro ediciones entre 2001 y 2008 con un creciente número de participantes tal y como muestra la Tabla 2.9 extraída de [122] y completada con los datos publicados para la BCI Competition IV en [123].

La diferencia más destacable entre las tres primeras ediciones y la última estriba fundamentalmente en dos áreas. Así, en el BCI Competition IV, los organizadores decidieron enfocar la competición a problemas derivados de los efectos de ERD/ERS, con un marcado pragmatismo en el que se dió un enfoque más práctico a los resultados. Del mismo modo, se reconoció que el hecho de publicar los conjuntos de datos permitía una colaboración interdisciplinar entre científicos especialistas en áreas diferentes a la neurociencia, incluyendo el procesamiento de señal, el análisis de datos o el diseño de algoritmos de clasificación.

Tabla 2.9: Historia de las BCI Competition en Números: número de conjuntos de datos provistos, número de presentaciones recibidas y número de laboratorios de investigación que participaron presentando soluciones [122, 123]

	Fecha	N. de Bases de datos	N. de opciones present.	N. Laboratorios
BCI Competition I	2001/2002	3	10	8
BCI Competition II	2002/2003	6	57	20
BCI Competition III	2004/2005	8	92	49
BCI Competition IV	2008	5	44	-

Dado que todos los conjuntos de datos se tomaron utilizando dispositivos BCI de investigación, y siguiendo la filosofía planteada en el BCI Competition IV, se ha decidido utilizar uno de ellos como referencia. De este modo ha sido posible evaluar la precisión alcanzada por dispositivos de captura de datos EEG de bajo coste en relación con el rendimiento de dispositivos profesionales para un problema específico. Esto permite realizar comparaciones relevantes sin la barrera que supone la adquisición de un equipo EEG de investigación.

El conjunto de datos utilizado fue publicado dentro del problema número cinco del BCI Competition III (en adelante BCI Competition III dataset V). Éstos fueron obtenidos por el *IDIA Research Institute of Switzerland* utilizando un dispositivo EEG de tipo Biosemi Active Two de 32 canales. El conjunto de datos provee dos variantes: potenciales eléctricos capturados en los 32 sensores y datos preprocesados, disponibles únicamente para los canales C3, Cz, C4, CP1, CP2, P3, Pz y P4.

Las características de ambos se detallan a continuación.




Figura 2.30: BCI Competition III Dataset V. Datos preprocesados: posiciones coloreadas en verde. Datos raw: todas las posiciones coloreadas (verde + azul)

### 2.7.1. Potenciales cerebrales

Las bioseñales cerebrales fueron capturadas sobre el cuero cabelludo de tres usuarios sin ningún tipo de minusvalía o enfermedad. Éstos se sentaron confortablemente sobre una silla y se les presentaron tres estados diferentes:

1. Pensar en mover continuamente la mano izquierda (clase 2, 'L').
2. Pensar en mover continuamente la mano derecha (clase 3, 'R').
3. Pensar en palabras comenzando por una misma letra definida (clase 7, 'W').

Las grabaciones se completaron durante el mismo día y fueron organizadas como sesiones de 4 minutos dedicados al experimento, en las que se le pidió a cada sujeto realizar durante 15 segundos y de forma aleatoria una de las tres diferentes tareas enumeradas. Entre esas sesiones se intercalaron una serie de periodos de descanso de entre 5 y 10 minutos. La frecuencia de muestreo fue de 512Hz y no se realizó ningún tipo corrección de las fuentes de ruido que hubiesen podido afectar a la señal.

Tres sesiones por usuario se proveyeron para el entrenamiento mientras que una última se utilizó como sesión de prueba para evaluar la precisión de las diferentes aproximaciones a este modelo. Asimismo, se definieron dos restricciones. En primer lugar, se impuso un límite a la cantidad de datos utilizada para proveer una respuesta. Esto se tradujo en que la longitud máxima de la ventana de datos para el preprocesamiento se limitó a un segundo, mientras que el número máximo de ventanas para el cálculo de la salida se restringió a las disponibles en el último medio segundo. Por otra parte, también se estableció en medio segundo la frecuencia en la respuesta presentada por el clasificador.

Todos los resultados mostrados en esta tesis doctoral se han calculado aplicando las dos restricciones anteriores por lo que los valores obtenidos son ciertamente comparables.

### 2.7.2. Datos preprocesados

Los datos preprocesados únicamente incluyen información de los canales C3, Cz, C4, CP1, CP2, P3, Pz y P4 (en verde en la Figura 2.30).

En primer lugar se aplica un filtrado espacial a partir de la aplicación de una superficie laplaciana (SL del inglés Surface Laplacian). Después, la extracción de características se realiza a partir del cálculo de la densidad espectral de potencia (PSD del inglés Power Spectral Density) utilizando ventanas de 1 segundo de datos. Dado que la resolución de los cálculos se divide en bandas de 2Hz entre las frecuencias de 8 y 30Hz, se generan 12 valores en cada cálculo. Si ésto se multiplica por el número de sensores (8 en este conjunto de datos), se proporcionan vectores preprocesados de 96 características.

Debido a la restricción derivada de realizar una predicción cada medio segundo y a la frecuencia de muestreo del dispositivo de captura, sólo 8 de estos vectores pueden ser considerados. Como resultado, se puede concluir que hay 8 vectores de 96 elementos disponibles para calcular cada predicción, que refleja la información obtenida por los sensores en el último segundo.

## 2.8. Preprocesamiento

Como se ha detallado anteriormente, en los sistemas EEG los electrodos situados sobre el cuero cabelludo del usuario capturan los potenciales eléctricos que genera la actividad cerebral en el rango entre 10 y  $100\mu\text{V}$ . Sin embargo, sólo el 50 % de la señal capturada en cada sensor proviene de fuentes situadas en un radio por debajo de los 3 cm de distancia ([124]). Por tanto, dada la diminuta amplitud de los potenciales cerebrales y el grado en el que interferencias provenientes de áreas tan dispares como el movimiento ocular, el latido del corazón, la respiración o la actividad muscular entre otras afectan a los mismos ([125]), se hace necesaria la aplicación de algoritmos filtrado de la señal.

En el área de la imaginación de movimiento, los más comúnmente encontrados en la literatura son:

1. Referencia media común (CAR del inglés Common Average Reference). Este método de filtrado se basa en sustraer al nivel de señal capturado en cada electrodo el nivel medio capturado en todo el sistema, generando una distribución espacial del voltaje de media cero libre de referencia. Este método se sustenta sobre la premisa de que el cuero cabelludo se cubre completamente de electrodos distribuidos regularmente y que los potenciales en el cerebro se encuentran generados por fuentes puntuales.
2. Método o superficie Laplaciana (SL del inglés Surface Laplacian). El modelo se basa en el cálculo de la derivada espacial de segundo orden de la distribución espacial instantánea del voltaje en el cuero cabelludo, enfatizando la actividad de las áreas más próximas a cada sensor. Al igual que el caso anterior, la distribución espacial de voltaje obtenida tras la aplicación de este método se encuentra libre de referencia. La distancia a los electrodos vecinos elegidos determina las características del filtrado, aumentando la sensibilidad a potenciales de un modo inversamente proporcional a la distancia entre el electrodo de referencia y los adyacentes. El cálculo de la misma



se suele realizar a través de una aproximación basada en un método de diferencias finitas tal y como se presenta en [126]. Dadas la ligereza del cómputo, los resultados obtenidos en referencias clásicas tales como [126, 127] y la extensiva utilización del mismo por la comunidad científica ([128]), es el método utilizado en esta tesis doctoral.

3. Patrones espaciales comunes (CSP del inglés Common Spatial Patterns). Se considera el mejor algoritmo de filtrado de la señal en el paradigma de los ritmos sensorimotrices y la imaginación de movimiento ([124, 123]). En su forma básica permite la diferenciación entre dos clases maximizando la varianza de una de ellas mientras minimiza la varianza de la otra. Dado que la varianza inicial de ambas clases se puede considerar la misma al estar tomadas con el mismo equipo, se puede considerar que utilizando CSP se aplica un filtro paso banda a las señales capturadas.

Cabe destacar que este método requiere de la correcta selección de dos parámetros, el filtro paso banda y los intervalos de tiempo. Ambos parámetros son dependientes del usuario y se suelen analizar datos del mismo para determinarlos, aunque también es posible utilizar parámetros generales. Igualmente, es posible *aprender* en sesiones con retroalimentación al usuario y existen aproximaciones para utilizar el algoritmo en problemas multiclase ([129, 130, 131]).

4. Análisis de componentes principales (ICA del inglés Independent Component Analysis). Este método se basa en la caracterización de la matriz de señal capturada en un vector multidimensional en el que cada componente es estadísticamente independiente, lo que implica que la información que posee una componente no se puede inferir de las restantes. Para ello, los cálculos se centran en encontrar un sistema de coordenadas en el que se maximice dicha independencia estadística a partir de diferentes medidas, que implican diferentes procesos de optimización y, por tanto, diferentes métodos ([132]).

En la Figura 2.31 se puede apreciar como la señal sin tratar no permite diferenciar entre las clases (imaginación de movimiento de la mano izquierda y derecha), mostrando un pico a 9Hz. Aplicando CAR se aprecia una cierta diferenciación, aunque no suficiente. Aplicando SL y CSP se revela una segunda componente espectral alrededor de los 12 Hz que sí que tiene un importante valor discriminatorio.

Asimismo, la señal debe estar caracterizada de modo que la etapa de clasificación posterior alcance una detección precisa de la intención del usuario. Los valores calculados por algoritmos como CSP no requieren de cambios y alimentan directamente a los clasificadores. Sin embargo, el resto de técnicas sí que se benefician de la caracterización frecuencial de la señal. Por tanto, se suelen encontrar en la etapa de preprocesamiento dos métodos para realizar este paso: el cálculo de la FFT y de la PSD de la señal.

1. Transformada rápida de Fourier (FFT del inglés Fast Fourier Transform). Es un algoritmo para el cálculo de la transformada discreta de Fourier (DFT del inglés Discrete Fourier Transform) que obtiene una representación en el dominio de la frecuencia de una señal discreta con un número de muestras potencia de dos.

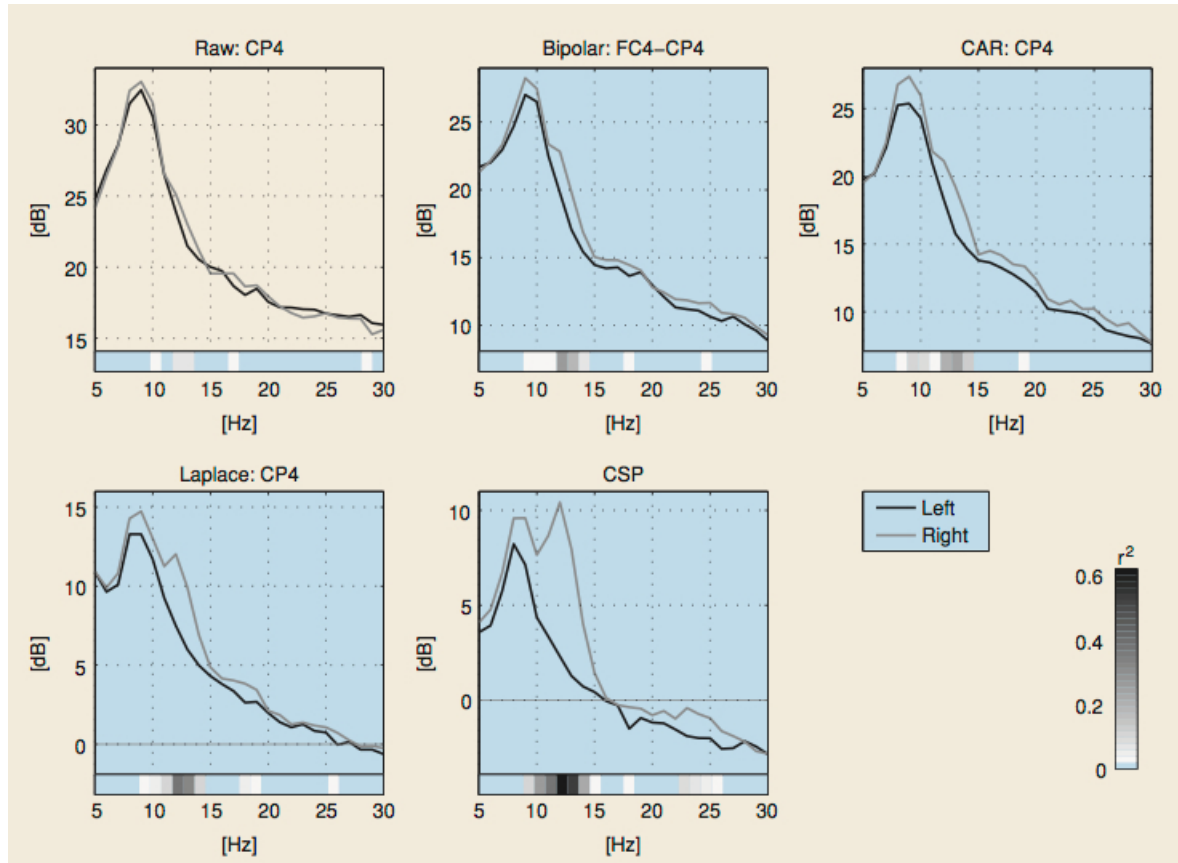


Figura 2.31: Espectro de la señal comparando imaginación de movimiento izquierda y derecha en raw y después de aplicar algoritmos de filtrado mejora de la señal [124]

2. Densidad espectral de potencia (PSD del inglés Power Spectrum Density). Esta función matemática calcula la distribución de la potencia de una señal en el dominio frecuencia. De este modo es posible conocer las componentes frecuenciales que acumulan una mayor energía y se aprecian de un modo más evidente las periodicidades. La potencia es considerada como el promedio de la señal lo que, en el dominio de la frecuencia, equivale al cuadrado de la magnitud de la FFT.

## 2.9. Clasificación

La etapa de clasificación es la responsable de transformar en última instancia la variable independiente, que son los potenciales leídos sobre el cuero cabelludo del usuario, en una señal de control que permita lanzar una serie de comandos para operar un sistema. Uno de los retos de los métodos de clasificación a largo plazo es proveer robustez en tres áreas: la adaptación inicial de cada usuario, la adaptación a las condiciones cambiantes del mismo

(fatiga, stress, nivel de atención, etc.) y la adaptación continua a medida que éste mejora su habilidad en el manejo del sistema.

Existe un amplio abanico de métodos de clasificación aplicados al problema BCI atendiendo a tipo de señal EEG en la que se basa el sistema y, para el paradigma de imaginación de movimiento, al número y tipo de movimientos definidos en el problema de referencia. Con el objetivo de proveer con la información más relevante posible, se ha decidido incluir en esta tesis doctoral únicamente aquellos que han mostrado un resultado en la etapa de clasificación por encima del conseguido con el trabajo ganador del BCI Competition III para el Dataset V. La Tabla 2.10 muestra un resumen de los modelos utilizados junto con el rendimiento alcanzado utilizando los datos anteriores sin realizar ningún tipo de selección de canales o características previo.

Tabla 2.10: Algoritmos de clasificación que han alcanzado una mayor precisión para el BCI Competition III dataset V

Autor	Acierto S1	Acierto S2	Acierto S3	Acierto Medio	Comentarios
Galan, F. et al. [133]	79.60	70.31	56.02	68.65	Ganador BCI Competition. Test utilizando el 10 % de los datos de entrenamiento.
Irtiza, N. et al [134]	81.16	70.27	56.51	69.31	
Cano-Izquierdo, J.M. et al. [135]	87.21	82.26	58.72	76.07	

1. Galan et al. [133] proponen el modelo ganador para el conjunto de datos utilizado en esta tesis doctoral. El funcionamiento del mismo se basa en:
  - a) Normalización dividiendo la PSD de cada característica entre la energía del canal.
  - b) Como método de extracción de características se aplica un algoritmo basado en la transformación de variables canónicas (CVT del inglés Canonical Variates Transformation), que es una generalización del discriminante lineal de Fisher para más de dos clases.
  - c) El método de clasificación es un modelo de análisis discriminante basado en la distancia (DBDA del inglés Distance Based Discriminant Analysis) utilizando como distancia de referencia la Euclídea.
  - d) Finalmente, un detector de transiciones de las tareas mentales (MTTD del inglés Mental Tasks Transitions Detector) elimina la clase predominante en las dos últimas transiciones, reduciendo el espacio de estados para nuevas muestras.
2. Irtiza, N. y Farooq, N. [134] realizan una comparación entre diferentes métodos de clasificación: análisis discriminante lineal (LDA del inglés Lineal Discriminant Analysis), Naive Bayes (NB), árbol de decisión (DT del inglés Decision Tree) y un sistema combinado utilizando en una primera fase LDA y en una segunda un DT. Puesto que sólo este último modelo presenta una tasa de acierto mayor que la del ganador de BCI Competition, es el único del que se explica brevemente su funcionamiento.

- a) Se utiliza el conjunto de datos preprocesados de 96 características formado por los datos de los sensores C3, Cz, C4, P3, Pz, CP1, CP2 y P4.
  - b) En la etapa de entrenamiento, se utilizan los datos de la primera sesión para entrenar el clasificador LDA y el árbol de decisión, que se basa en un modelo de tipo bosque aleatorio (RF del inglés random forest).
  - c) En la etapa de clasificación, se presentan los datos al clasificador LDA y los que son erróneamente clasificados, pasan al árbol de decisión.
3. José-Manuel Cano-Izquierdo [135] y su equipo superaron al ganador del BCI Competition III para este juego de datos en 2012. Lo hicieron proponiendo la aplicación de un sistema neuro difuso de tipo S-dFasArt, al cual se añadió una etapa de poda de reglas y otra de votación. Puesto que este modelo era el de mayor tasa de acierto cuando se comenzó la realización de esta tesis doctoral, fue el elegido para la realización de la misma. Por este motivo, su estructura se detalla con un mayor detalle en el siguiente punto.

### 2.9.1. Algoritmos neuro difusos - Modelos ART

La teoría de la resonancia adaptativa (ART del inglés Adaptative Resonance Theory) se basa en la definición de una serie de módulos básicos que permiten la construcción de redes neuronales artificiales basadas en arquitecturas más complejas. Éstas tienen como pretensión reflejar una serie de propiedades que son inherentes a los sistemas neurológicos, tales como el dilema estabilidad-plasticidad [136], el de ruido-saturación o el de máxima generalización con mínimo error.

Los sistemas de tipo ART se basan en una arquitectura básica como la mostrada en la Figura 2.32, incluyendo dos capas: una capa de entrada ( $F1$ ) y una de salida ( $F2$ ). En la capa de entrada se normalizan los datos y las neuronas toman los valores normalizados calculados. Los pesos de las mismas dentro de la red transforman los valores recibidos en un vector  $T$ . La red competitiva de la capa de salida, transforma el vector  $T$  en un código comprimido de salida  $y$ . Siguiendo el modelo competitivo, la neurona ganadora es la que presenta un mayor grado de activación.

En este tipo de sistemas, la clasificación y el aprendizaje ocurren de forma simultánea y no hay límite en la información que se puede almacenar. En una primera instancia, los valores de los parámetros de la salida que excitan la neurona seleccionada se envían a la capa  $F1$ , junto los señales inhibitorias no aprendidas. En ésta, se comparan ambos valores y se obtiene un vector  $x^*$  que representa las características críticas de la entrada en relación con la salida. Si el valor  $x^*$  se parece suficientemente a la entrada  $I$ , el valor de la activación en  $F2$  converge hacia  $x^*$ .

El valor del parámetro de vigilancia  $\rho$  determina la cantidad de la señal original que debe permanecer en  $x^*$  para que se puedan asociar la entrada  $I$  con la salida  $y$ . Su valor se define entre 0 y 1 y es un parámetro de la red ART. Un valor próximo a 0 representa un criterio de similitud laxo en el cual multitud de entradas serán clasificadas en una misma categoría, mientras que un valor próximo a 1 determina un criterio exigente, en el cual se crearán múltiples categorías nuevas en la capa de salida. En este último escenario

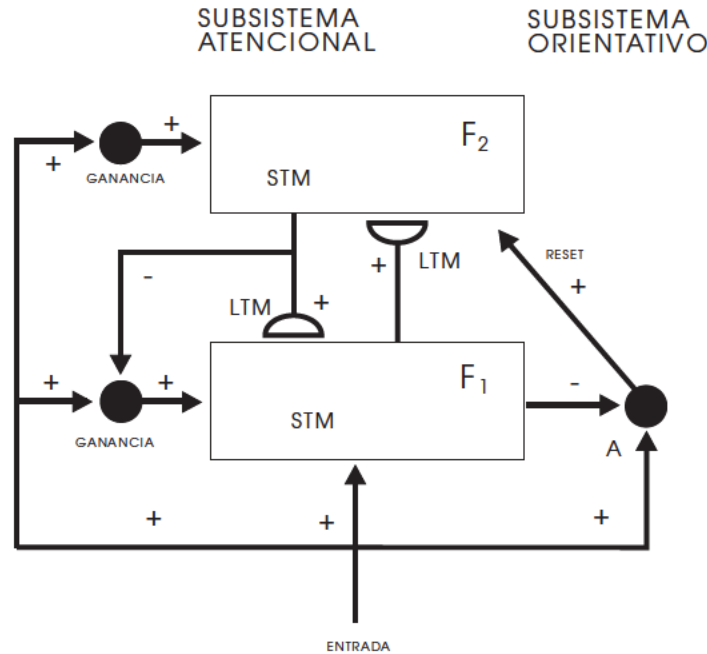


Figura 2.32: Estructura fundamental de una red de tipo ART [137]

$\rho$  determina si la neurona ganadora debe ser desactivada y ha de buscarse otra neurona ganadora. Cuando no se encuentre ninguna otra neurona ganadora, el sistema puede crear una nueva neurona en F2 o descartar la entrada.

Las redes ART han experimentado una evolución constante a lo largo del tiempo.

1. ART 1. Es el modelo original y funciona tal y como se ha explicado anteriormente. Es capaz de trabajar únicamente con entradas binarias.
2. ART 2. Adapta la arquitectura ART al tratamiento de señales continuas. Uno de los cambios más representativos es la definición de la capa de entrada F1 a partir de tres subcapas de procesamiento: una capa lee la señal de entrada, otra la señal que se propaga hacia abajo desde F2, y una etapa intermedia busca la correspondencia entre ambos vectores antes de enviar el patrón a F2.
3. ART 2-A. Es una arquitectura ART 2 que consigue una mayor rapidez en la ejecución manteniendo las prestaciones.
4. ART 3. Aborda el problema de la búsqueda paralela en arquitecturas ART jerárquicas compuestas de módulos ART 2. Las conexiones dentro y entre módulos ART se modelan como procesos sinápticos que incluyen la producción y liberación de sustancias transmisoras, la desactivación post sináptica del transmisor y la modulación de tales procesos a partir de una señal de control no específica [138].

5. Fuzzy ART. Este modelo incorpora la teoría de conjuntos difusos a una arquitectura de tipo ART 1, donde los operadores lógicos se reemplazan por operadores difusos. Cabe destacar que esta arquitectura, a diferencia de ART 1, permite el tratamiento de entradas analógicas. Del mismo modo, se incorpora una etapa de preprocesamiento llamado código complementario que resuelve el problema de proliferación de categorías.
6. ARTMAP. Se aborda el aprendizaje supervisado a partir de la unión de dos módulos ART 1 (ARTa y ARTb) interconectados entre ellos por un mapa Inter ART. Uno de ellos tiene como entrada el vector a clasificar y otro la predicción correcta. Por su parte, el mapa Inter ART se compone de tantas neuronas como la capa F2 de ART-b, con la que tiene una conexión una a una. Éstas también se conectan con todas las neuronas existentes del módulo ARTa, definiendo la conexión a partir de un vector de pesos. Cuando las unidades activadas en el mapa Inter ART por los dos módulos ART coinciden se produce un refuerzo de los pesos. En caso contrario, se activa el RESET Inter ART, que eleva el parámetro de vigilancia de ARTa, y se repite el proceso de catalogación. En esta arquitectura se incluye además un sistema de *match tracking* que ayuda a la red a tratar predicciones de eventos raros dentro de un conjunto de eventos frecuentes de una clase diferente.
7. Fuzzy ARTMAP. En este modelo se incorpora la teoría de conjuntos difusos a un clasificador con aprendizaje en modo supervisado. La arquitectura de este modelo incluye dos módulos Fuzzy ART (Fuzzy ARTa y Fuzzy ARTb) unidos a través de un mapa Inter ART, a los que se añade un mecanismo de RESET análogo al de la arquitectura ARTMAP. El funcionamiento es equivalente al de la arquitectura ARTMAP, con la salvedad del tratamiento de los datos utilizando operadores difusos.
8. FasArt [139]. Aporta una definición formal de las categorías como conjuntos difusos. De esta manera se consigue establecer una equivalencia entre la función de activación de cada unidad y la función de pertenencia asociada al conjunto difuso definido sobre el universo de cada una de las componentes del vector de entrada. Estos universos quedan representados por los pesos de las neuronas de la capa F2. Dada esta interpretación, se puede establecer el valor de certeza para la estimación propuesta en base al aprendizaje realizado y definir el riesgo máximo permitido del sistema.
9. FasBack [139]. A las características aportadas por FasArt, FasBack une el aprendizaje basado en la minimización del error de predicción, por lo que es necesario encontrar los parámetros del sistema capaces de minimizar el mismo. En este método se utiliza la técnica de gradiente descendente a tal fin. La optimización de la forma de los conjuntos fuzzy de ARTb hacia sus centros, de las conexiones que forman las reglas a través de los pesos del mapa inter-ART (únicamente de las que se encuentran activas para un vector de entrada) y de la forma de los conjuntos fuzzy de ARTa realizadas de forma combinada ofrece los mejores resultados. De este modo, le objetivo es encontrar el conjunto de componentes del vector de parámetros que minimizan el error local de predicción para una cierta variación de la entrada.

10. dFasArt [140]. Dado que los modelos de tipo ART realizan un aprendizaje incremental, es importante tener en cuenta las características temporales de los patrones de entrada (orden de llegada y persistencia). Por tanto dFasArt (dynamic FasArt) añade ecuaciones dinámicas para el cálculo de la señal de RESET, el aprendizaje de los pesos y las ecuaciones de activación. De este modo, se añaden parámetros como la tasa de decaimiento o la ganancia de excitación a las ecuaciones de cálculo de los parámetros anteriores, que sirven para capturar de una mejor manera las particularidades temporales de la entrada.
11. S-dFasArt. Al ser éste el modelo utilizado en la etapa de clasificación en esta tesis doctoral, se explica con detalle en el siguiente apartado.

### 2.9.2. Supervised and dynamic Fuzzy Adaptative System ART-base (S-dFasArt)

El S-dFasArt ([135]) es la versión supervisada del modelo dFasArt y ha sido el método de clasificación utilizado en la evaluación de la precisión del sistema BCI de bajo coste propuesto en esta tesis doctoral.

Como principio básico, a su vez asociado a las arquitecturas de tipo ART, el modelo S-dFasArt satisface el principio de estabilidad/plasticidad, ya que posibilita el mantenimiento del conocimiento en la red a la vez que es capaz de continuar aprendiendo y adaptarse ante nuevos parámetros de entrada. En la arquitectura del modelo S-dFasArt se pueden distinguir cuatro elementos principales: el Nivel de Entrada, el Nivel de Supervisión, el Nivel de Categorización y el Subsistema de Orientación (Figura 2.33).

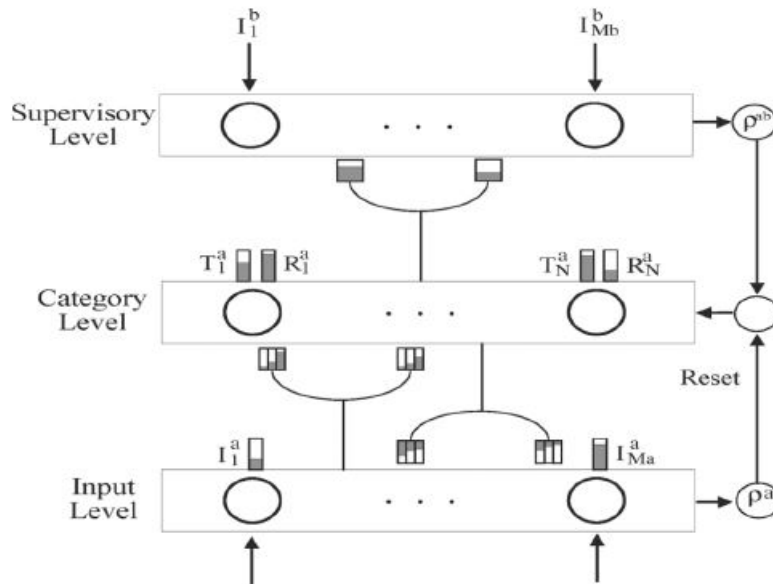


Figura 2.33: Arquitectura del modelo S-dFasArt [135]

1. El nivel de entrada está formado por  $M_a$  nodos que evalúan el grado de pertenencia de cada elemento  $i$  del vector de entrada  $I^a$  a cada una de las categorías del sistema  $j$ . En cada uno de ellos se integra un bloque difuso que incluye una función de activación/pertenencia  $\eta_{ji}$  de tipo triangular, cuyo tamaño queda definido a partir del parámetro de diseño  $\sigma$ , como se muestra en la Figura 2.34.




Figura 2.34: Función de activación/pertenencia para cada nodo  $A^j$  del nivel de entrada en el modelo S-dFasArt [135]

2. El nivel de supervisión se compone de  $M_b$  nodos, los cuales durante la etapa de aprendizaje se asocian a cada una de las  $d$  categorías del vector  $I^b$  que se pretenden distinguir dentro del conjunto de datos.
3. El nivel de categorización se encuentra compuesto por  $N$  unidades que representan las categorías creadas durante el proceso de aprendizaje. Cada nodo se caracteriza por dos parámetros:  $T_j$  o grado de activación y el  $R_j$ , que define la capacidad de aprendizaje de dicha neurona. Además, las características difusas de los mismos quedan definidas a partir de los valores de los pesos: mínimo  $W_{ji}$ , central  $C_{ji}$  y máximo  $V_{ji}$ , que definen el grado de pertenencia difusa del vector de entrada a la categoría que se encuentre reaccionando. Cada categoría difusa sólo puede codificar un estado de salida  $CC$  de las  $d$  posibilidades generadas durante la etapa de aprendizaje desde los valores de supervisión. Las categorías se activan con un determinado nivel  $T_j$  cuando se presenta un patrón de entrada al clasificador, dependiendo del grado de pertenencia difusa del vector de características de entrada. La categoría ganadora es entonces la que presenta un mayor nivel de activación.
4. El subsistema de orientación es el responsable de determinar el nivel de similaridad entre la entrada y las categorías existentes. El elemento más importante dentro de la arquitectura es el parámetro de vigilancia  $h(\rho)$ , que determina el número máximo de categorías difusas dentro del nivel de categorización. Para ello el sistema de *match tracking* regula automáticamente el parámetro de vigilancia y determina si la similaridad entre la entrada y la categoría  $j$  permite clasificar la entrada como perteneciente a dicho nodo. En caso negativo, se produce un nivel de reset  $R_j$  para



deshabilitar la categoría actual y elegir otra siguiendo el criterio de máxima similitud. En caso de que no haya categorías con una similitud suficiente se crea una nueva igual a la entrada presentada al sistema.

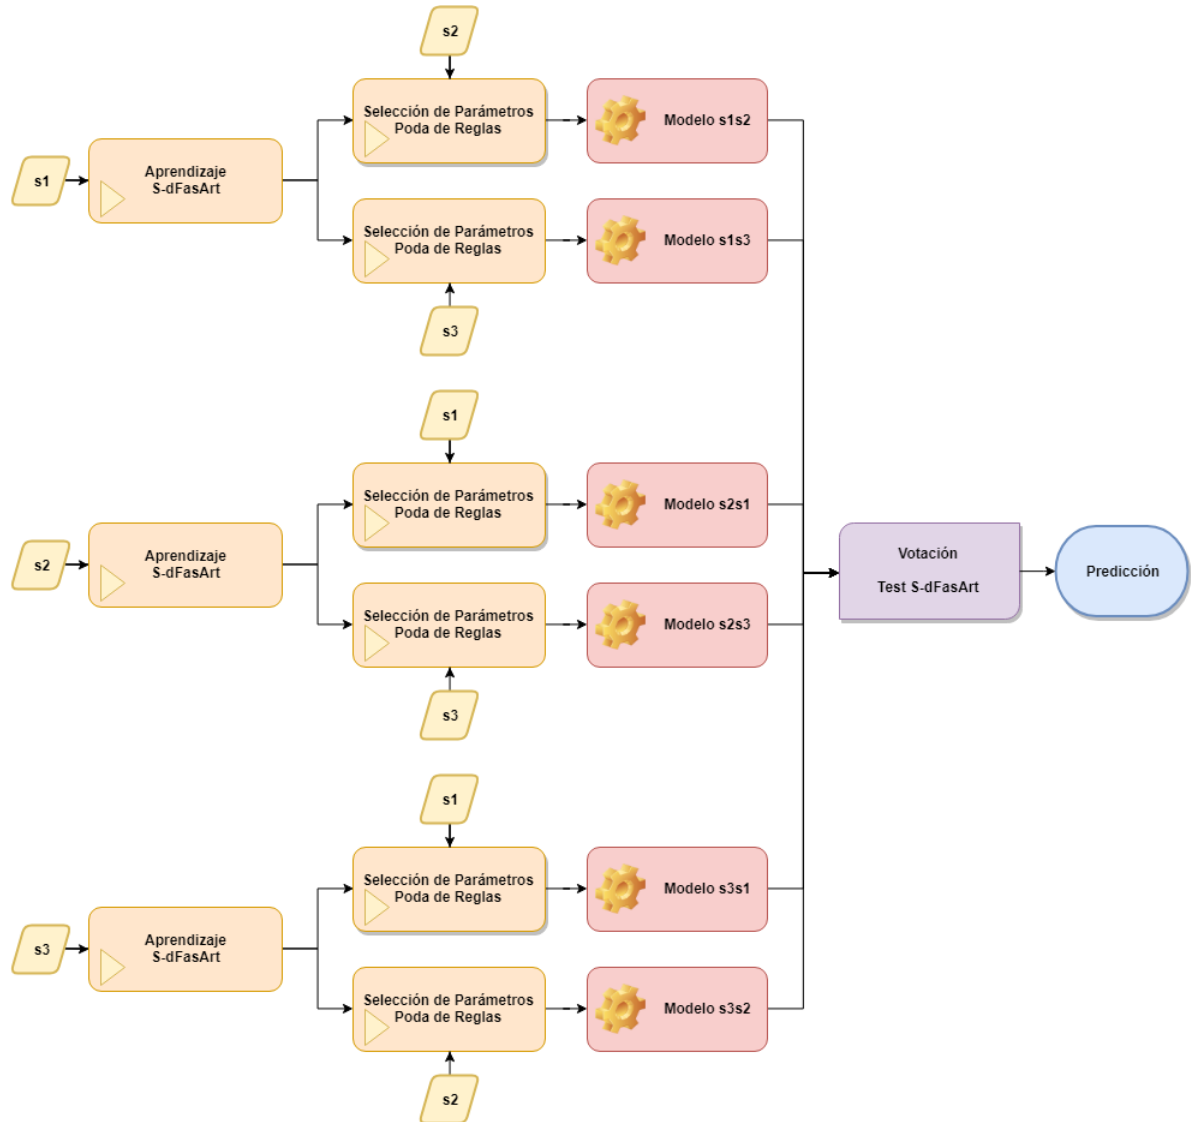


Figura 2.35: Arquitectura del sistema S-dFasArt utilizado

Dentro de las características fundamentales del modelo se puede destacar la dualidad neuro-difusa, que permite tanto la descripción del sistema como un conjunto de reglas conectando categorías difusas como la visión del mismo como una red neuronal de tipo ART con aprendizaje incremental basado en la entrada. Del mismo modo, respeta el criterio de máxima generalización con mínimo error, adaptando el tamaño de las categorías de

acuerdo con el vector de entrada.

De un modo más preciso, en esta tesis doctoral se ha tomado como base la metodología propuesta por Cano et. al. ([135]), donde se distinguen tres fases (Figura 2.35). Para un conjunto de datos formado por tres sesiones de entrenamiento y una de test, se utilizan las sesiones  $s_1$ ,  $s_2$  y  $s_3$  de forma individual para que tres módulos clasificadores S-dFasArt completen la etapa de aprendizaje, obteniéndose como resultado los pesos de la red. Después, las sesiones restantes de aprendizaje se combinan con la utilizada para realizar el ajuste de los dos parámetros fundamentales de la red ( $\sigma$ , que modifica el tamaño de la función triangular de activación-pernencia, y  $A_t$ , que identifica a la velocidad de activación de las neuronas de la red), así como una poda de las reglas difusas existentes en la cual únicamente aquellas que poseen una tasa de acierto mayor que la de error se mantienen. Es decir, para el clasificador S-dFasArt que aprendió con los datos de entrenamiento  $s_1$ , se utilizan  $s_2$  y  $s_3$  para realizar el ajuste de parámetros y la poda de reglas. Como resultado se obtienen seis modelos diferentes disponibles para realizar la predicción, que proveen de una salida intermedia.

Finalmente, el último módulo ofrece como salida aquella que aparece mayoritariamente entre las salidas intermedias.

## 2.10. Algoritmos de Selección de Características

En los sistemas BCI basados en EEG se capturan señales en múltiples posiciones del cuero cabelludo con el objetivo que determinar la intención del usuario. Desde el punto de vista científico no todos los datos capturados son relevantes para el estudio de problemas específicos, por lo que se puede considerar parte de las señales capturadas como una componente de ruido añadida al sistema. Por tanto el problema de la selección de características se basa en encontrar el subconjunto óptimo dentro del conjunto de componentes original que, utilizado para entrenar el algoritmo de clasificación seleccionado, maximiza su rendimiento.

Además, la reducción de los datos conlleva una simplificación en la complejidad de los modelos a aplicar, un mayor conocimiento de la zona cerebral que se excita y una reducción de la carga computacional. Igualmente, desde la perspectiva de un consumidor final, minimizar el número de electrodos ayuda a reducir la complejidad de los equipos, lo que redundará en una reducción del coste de fabricación y de la dificultad en el uso, que son importantes barreras de entrada fuera de los ámbitos científico y médico. Del mismo modo, sistemas con un menor número de sensores capturan y procesan menos datos, lo que incrementa la duración de las baterías y permite la utilización de los mismos integrados en sistemas móviles durante un mayor periodo de tiempo.

Existen fundamentalmente dos aproximaciones a la búsqueda de dichos parámetros: filtros y envoltorios [141]. En la primera, el espacio de características se filtra de forma previa a la utilización de los datos por el algoritmo de aprendizaje, por lo que se ignora el efecto en el rendimiento de éste durante la etapa de aprendizaje. En la segunda, el proceso de selección de características realiza la búsqueda de un subconjunto óptimo de datos utilizando el propio algoritmo de aprendizaje, formando parte de la función de evaluación

de los subconjuntos de características. El modelo de funcionamiento es sencillo, el algoritmo se ejecuta sobre el conjunto de datos, normalmente particionado entre un subconjunto de datos interno y uno de test, tomando diferentes subconjuntos de componentes. El subconjunto de características que consigue la mayor precisión es el elegido para ejecutar el algoritmo de clasificación.

Igualmente, se puede encontrar una tercera categoría que denomina métodos empotrados (del inglés *embedded*) a aquéllos en los que el proceso de aprendizaje y los algoritmos de selección de características son indivisibles [142].

Existe un amplio abanico de estrategias para abordar este problema en experimentos relacionados con la imaginación de movimiento. No obstante, sólo los métodos utilizados sobre el conjunto de datos Dataset V del BCI Competition III son enunciados en este punto.

1. Ricardo Aler y su equipo proponen en [143] la utilización del algoritmo CMA-ES (del inglés *Covariance Matrix Adaptation Evolution Strategy*) para optimizar simultáneamente el filtro espacial para el preprocesamiento de los datos de entrada y el filtro sobre la matriz de características, que actúa como selector de las mismas. Como función objetivo se utiliza el discriminante de Fisher (FD del inglés *Fisher Discriminant*) dada la baja carga computacional de los cálculos. En la fase de test, se utilizan máquinas de vector soporte (SVM del inglés *Support Vector Machine*) como clasificador para comparar los diferentes resultados. Cabe destacar que la selección de características realizada incluye datos de todos los sensores, por lo que el número de componentes totales seleccionadas ha de multiplicarse por el número de canales cuyos datos son procesador por el sistema.

El algoritmo CMA-ES es un algoritmo de búsqueda de tipo genético. En este tipo de algoritmos se inicializan una serie de cromosomas forma aleatoria sobre el espacio del vector de entrada que funcionan como una máscara, definiendo las características a evaluar. En cada generación se requiere una evaluación de los resultados en base a una función objetivo, que también puede ser el rendimiento de un clasificador, lo que permite determinar si una determinada componente es apropiada dentro de la selección. De este modo es posible obtener las poblaciones de individuos que están mejor capacitadas y cruzarlas o mutarlas hasta conseguir una convergencia, generando cromosomas nuevos siguiendo un proceso de adaptación natural, ya sea a partir de un objetivo o de un número definido de iteraciones. Ejemplos de estos algoritmos se pueden encontrar en también en [144, 145].

2. Andrés Úbeda et al. [146] utilizan un nuevo método de clasificación basado en el análisis de mapas EEG, asociado tradicionalmente al diagnóstico de enfermedades mentales como la epilepsia o la esquizofrenia. A partir de los datos preprocesados del Dataset V interpolan los valores a un grid de 99x99 píxeles en el cual se sitúan los sensores en sus posiciones aproximadas. Entonces realizan una serie de mapas mostrando la energía asociada a cada frecuencia y tarea mental utilizando un tiempo de procesado específico entre 1 y 5 segundos. Finalmente, estos mapas se promedian, dando como resultado tres mapas, uno para cada tarea. La clasificación de cada

entrada se basa en la comparación entre la misma y los modelos utilizando el cálculo de la correlación cruzada normalizada (del inglés *normalized cross-correlation*). Después de esta comparación se obtiene un índice de correlación para cada tarea, y se elige como resultado la tarea asociada al mayor de los mismos. No obstante, la clasificación sólo se considera válida cuando el resto de los índices se encuentra por debajo de un cierto valor de incertidumbre.

Como parte de la optimización de los parámetros del clasificador se propone una búsqueda de las frecuencias óptimas de entre las 12 bandas de frecuencia del conjunto de datos (8-30Hz en bandas de 2 Hz). Para obtener las mismas se aplica el clasificador utilizando una validación cruzada con tres sesiones para los modelos y una para pruebas, seleccionando aquella frecuencia que ofrece una mayor tasa de acierto. Cabe destacar que dicha frecuencia se elige para todos los canales del conjunto de datos, por lo que en realidad existen ocho características frecuenciales diferentes, una para cada canal.

3. Jaime F. Delgado Saa y Müjdat Çetin [147] proponen la utilización de campos aleatorios condicionales (CRF del inglés *Conditional Random Fields*) y de campos aleatorios condicionales dinámicos latentes (LDCRF del inglés *Latent Dynamic Conditional Random Fields*) para la clasificación de datos BCI. CRF se puede utilizar para modelar las dinámicas de datos secuenciales entre diferentes tareas, aunque carece de la capacidad de modelar dichas dinámicas de forma intrínseca dentro de una misma tarea. LDCRF, por el contrario, permite modelar estados diferentes durante la ejecución de una tarea mental específica al mismo tiempo que se modelan las transacciones entre diferentes tareas mentales. Por consiguiente, LDCRF se puede aplicar directamente a los datos secuenciales sin aplicar ningún algoritmo de procesamiento por ventana.

La selección de características propuesta se lleva a cabo en base a una selección hacia delante flotante secuencial (SFFS del inglés *sequential Floating Forward Selection*). En primera instancia, se realiza una selección inicial de las características sobre los datos preprocesados, promediándose la potencia entre las frecuencias de las bandas  $\alpha$  (8Hz-12Hz),  $\sigma$  (12Hz-16Hz) y  $\beta$  (18Hz-26Hz) para cada canal, clase y sujeto. Por tanto, se crea un nuevo vector de 24 características para cada usuario. Como segunda parte, en cada interacción del algoritmo SFFS se evalúa la eliminación de una de las características del vector de entrada proporcionado, deshaciéndose de todas aquellas que disminuyen la precisión global del sistema.

Los valores mostrados para el número de características en la Tabla 2.11 desagregan los datos de las diferentes bandas con el objetivo de hacerlos comparables con el resto de las aproximaciones.

Cabe destacar que los resultados publicados en [146, 147] vulneran la condición de utilizar únicamente el último segundo de los datos para calcular la salida que se establece en el Dataset V del BCI Competition III.

Además de estos modelos, se quisiera destacar la amplia literatura que existe en torno a evoluciones del algoritmo CSP en la selección de características, de lo cual las referencias

Tabla 2.11: Algoritmos de selección de características que han alcanzado una mayor precisión para los datos BCI Competition III dataset V

<b>Autor</b>	<b>Acierto S1</b>	<b>Caract</b>	<b>Acierto S2</b>	<b>Caract</b>	<b>Acierto S3</b>	<b>Caract</b>	<b>Acierto Medio</b>
Aler, R. et al. [143]	78.14	32	71.33	16	59.07	40	69.58
Ubeda, A. et al. [146]	85.71	8	73.80	8	64.28	8	74.60
Saa, J.F.D. et al. [147] - CRF	92.95	14	89.63	28	61.81	12	81.46
Saa, J.F.D. et al. [147] - LSCRF	95.63	14	89.75	24	72.36	10	85.91

[148, 149, 150, 151, 152] dan buena cuenta. Del mismo modo, se pueden encontrar otras aproximaciones en diferentes estudios estado del arte y comparaciones [128, 153].



## Capítulo 3

# Evaluación del sistema EEG Emotiv EPOC

La tecnología EEG es la predilecta por la comunidad científica para la lectura de datos cerebrales en seres humanos. Tradicionalmente, los equipos utilizados se clasifican atendiendo a su número de sensores y características (fundamentalmente secos o húmedos), la frecuencia de muestreo y la capacidad de los mismos para amplificar las señales cerebrales mientras se minimiza el impacto del ruido ambiental. Dada la mínima amplitud de la señal cerebral con respecto a las fuentes de ruido internas y externas, la caracterización de la misma demanda que los equipos de captura incluyan componentes de precisión que elevan su coste. Igualmente, su uso requiere conocimientos que no están al alcance del consumidor final.

No obstante, no sólo los aspectos técnicos o económicos son relevantes para la adopción de sistemas BCI basados en electroencefalografía, también se han identificado áreas como la facilidad de uso, el funcionamiento bajo demanda y la robustez como elementos clave [7].

Los dispositivos EEG de bajo coste suponen un acercamiento al consumidor final basado en un compromiso entre la precisión en la obtención de la señal y el coste de los componentes utilizados para la fabricación de los mismos. Estos sistemas integran normalmente un número de sensores reducido y en posiciones fijas, con una frecuencia de muestreo menor y una tecnología en los elementos de captura de datos más sencilla. Como consecuencia son más fáciles de utilizar, poner y quitar, integran conexiones inalámbricas que facilitan la movilidad y se integran en elementos plásticos que incrementan su robustez. La aparición de los mismos, en principio como sistemas para el control de video juegos, también ha posibilitado una democratización en el acceso a las señales generadas en cerebro humano.

Por tanto, la comparación entre el rendimiento de los equipos EEG de bajo coste y aquellos utilizados frecuentemente en el ámbito de la investigación es un área de creciente interés para la comunidad científica. El objetivo final es determinar en qué tipos de sistemas BCI se pueden incluir dispositivos de captura de datos de bajo coste.

El propósito de este capítulo es evaluar la precisión conseguida por un sistema EEG

de bajo coste usando como referencia potenciales capturados por un equipo profesional desde la perspectiva de un sistema BCI completo. Así, se comparan datos recogidos utilizando tres sistemas de encefalografía diferentes: aquellos disponibles del BCI Competition III dataset V, datos obtenidos con un sistema Emotiv EPOC híbrido (integrando una malla de tipo Easycap) y datos capturados con el casco EEG Emotiv EPOC estándar. Cabe destacar que tanto la base de datos con el sistema Emotiv EPOC híbrido como las generadas con Emotiv EPOC estándar son de elaboración propia.

Del mismo modo, los nuevos juegos de datos se obtienen a partir del problema de referencia presentado en el BCI Competition III dataset V, basado en un paradigma de imaginación de movimiento multiclase. Dado que tanto los colaboradores en el experimento como la distribución de los sensores en los diferentes escenarios es distinta, se considera adecuada la opción de comparar dichos sistemas datos a nivel de aplicación, evaluando su precisión cuando se completa la misma tarea: predecir una acción mental.

### 3.1. Captura de Datos

#### 3.1.1. Conjuntos de datos

Para la realización de esta tesis doctoral se utilizan seis conjuntos de datos, basándose todos ellos en la reglas establecidas para el experimento definido en el BCI Competition III dataset V. Para alcanzar dicho objetivo se usa Matlab junto al kit de desarrollo de software (SDK del inglés Software Development Kit) provisto por Emotiv para desarrollar una aplicación que recrea el escenario, captura los datos, los procesa y los entrega en el mismo formato que los aquellos del BCI Competition III (la Figura 3.1).

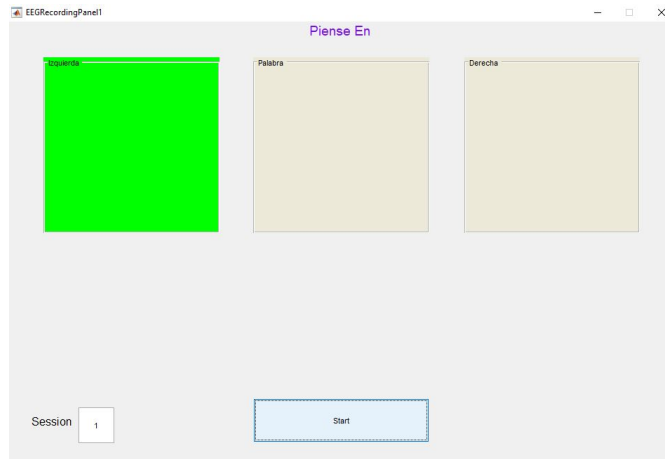


Figura 3.1: Interfaz gráfico de la aplicación de captura de datos

De un modo más preciso, se comparan:

1. Datos pertenecientes a la base de datos BCI Competition III dataset V:



- a) Datos preprocesados del BCI Competition. Se hace uso de la información de la actividad perteneciente a los canales C3, Cz, C4, CP1, CP2, P3, Pz y P4, situados sobre la zona centro-parietal del cerebro.
  - b) Datos raw BCI Competition. Se extraen y se preprocesan los datos de los canales coincidentes con aquellos definidos para Emotiv EPOC (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4).
2. Datos raw propios capturados de usuarios realizando el experimento voluntariamente debidamente preprocesados:
- a) Datos capturados con Emotiv EPOC. Se incluyen las señales cerebrales capturadas en los 14 canales disponibles (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4). Esta primera base de datos se compone de tres sujetos.
  - b) Datos obtenidos con el sistema híbrido Emotiv EPOC - EasyCap en las posiciones BCI Competition. Comprende datos de tres colaboradores en las posiciones centro-parietales del cerebro (C3, CZ, C4, CP1, CP2, P3, PZ, P4).
  - c) Datos extraídos con el sistema híbrido Emotiv EPOC - EasyCap en las posiciones estándar para Emotiv EPOC. Abarca datos de tres individuos en las posiciones AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4.
  - d) Datos capturados con Emotiv EPOC para una población de 12 usuarios. Esta base de datos tiene como objetivo realizar un estudio más amplio y comprobar la capacidad de generalización de los resultados previos.

Así mismo, y para facilitar comparaciones entre los resultados obtenidos de cada experimento, se crea la nomenclatura presentada en la Tabla 3.1.

Tabla 3.1: Nomenclatura definida para los conjuntos de datos utilizados en esta tesis doctoral

Identificador	Base de Datos
BCIComp	Datos preprocesados de BCI Competition
BCIEpoc	Datos raw BCI Competition utilizando los canales Emotiv EPOC
EmoEpoc	Datos capturados con Emotiv EPOC - base de datos de 3 usuarios
EasyBCI	Datos obtenidos con Emotiv EPOC - EasyCap canales BCI Competition
EasyEpoc	Datos extraídos con Emotiv EPOC - EasyCap canales Emotiv EPOC
EmoExt	Datos capturados con Emotiv EPOC para una población de 12 usuarios

### 3.1.2. Experimento y participantes

Los datos propios se recopilan gracias a la colaboración desinteresada de un total de 19 usuarios entre los 10 y los 69 años ( $35.4 \pm 14.5$ ), 4 de ellos mujeres, quienes realizan

el experimento definido en el BCI Competition III DataSet V en una sala no eletromagnéticamente aislada, pero sí en un entorno tranquilo y con un limitado nivel de ruido ambiental. Ninguno de ellos presenta patologías mentales diagnosticadas o se encuentra tomando medicación que pueda afectar su función mental. Todos ellos participan en la base de datos final de Emotiv EPOC, y sólo algunos lo hacen en la creación de las otras bases de datos. Por tanto, se añaden los datos específicos de la población de participantes junto a cada experimento. El protocolo de realización del experimento comprende los siguientes pasos:

1. Acomodación de los usuarios y colocación del sistema EEG de captura de datos seleccionado (Emotiv EPOC o híbrido).
2. Explicación a grandes rasgos del motivo por el que se elige experimento en cuestión y la información que se intenta obtener a partir de la ejecución del mismo.
3. Familiarización con la mecánica del cerebro. Para simplificar el entendimiento se asocia el experimento con el conocimiento extendido de que los movimientos de los miembros de la parte derecha del cuerpo humano se generan en el hemisferio izquierdo de cerebro y viceversa. Del mismo modo, se añade como novedad el hecho de que realizarlos e imaginarlos genera el mismo patrón cerebral [154].
4. Fase de relajación. En esta fase se anima a los usuarios a relajarse y liberar su mente de la rutina diaria. Para un mejor entendimiento de la dificultad del problema abordado se utiliza una analogía, en la cual se compara el cerebro humano con escuchar y entender a un comensal hablando en un restaurante. Fundamentalmente se explica a los colaboradores que en el cerebro existen multitud de pensamientos, cual voces de personas hablando en un restaurante al mismo tiempo. Igualmente, se añade que el pensamiento que se intenta capturar y traducir se encuentra mezclado con cualquier otro pensamiento cerebral, y afectado por los latidos del corazón o el movimiento muscular, lo cual sirve para enfatizar la importancia de la concentración y la relajación.
5. Desmitificación. Del mismo modo, se subraya que de ninguna manera el experimento es una competición o un test de inteligencia.
6. Descripción detallada del experimento. Se explica tal y como aparece enunciado para el BCI Competition.
7. Compromiso con el colaborador. Antes de comenzar el experimento se expresa el compromiso de proveer el resultado de clasificación propio alcanzado una vez se procesen los datos utilizando S-dFasArt.
8. Realización del experimento.
  - a) Protocolo. Para llevar a cabo la toma de datos los usuarios se sientan en un sillón de oficina frente a la pantalla de un ordenador portátil con los brazos relajados descansando sobre sus rodillas (Figura 3.2). Cada uno de ellos completa




Figura 3.2: Posición de los usuarios en la captura de datos utilizando Emotiv EPOC

en esta posición cuatro sesiones, con un periodo de descanso de entre 5 y 10 minutos entre ellas. Las grabaciones para cada usuario se hacen en mismo día, utilizándose tres de ellas para entrenar y construir el clasificador y una última para comprobar el rendimiento del mismo. Cada sesión dura 4 minutos y consiste en alternar tres pensamientos diferentes presentados de forma aleatoria a intervalos de 15 segundos sin presentar ningún tipo de realimentación al usuario, lo que impide a los mismos alterar su forma de pensar para optimizar los resultados. Con el objetivo de producir conjuntos de datos comparables, estos pensamientos son: mover continuamente la mano izquierda hacia la izquierda, mover continuamente la mano derecha hacia la derecha e imaginar palabras comenzando por una misma letra. Para minimizar los problemas durante los primeros segundos de cada experimento se añade un temporizador de espera de 10 segundos, que ayuda a los voluntarios a relajarse y estabilizar su posición en la silla antes del comienzo de cada sesión.

- b) Software desarrollado. Los datos son obtenidos con una aplicación desarrollada en Matlab a tal efecto como parte de este trabajo doctoral. Ésta consta de un interfaz gráfico (Figura 3.1) integrado con un sistema de captura de datos accediendo directamente a los valores de los potenciales eléctricos leídos sobre el cuero cabelludo de los individuos. Así, no es necesario ningún tipo de alineación posterior de los datos y se puede asegurar que éstos ciertamente corresponden a las tareas definidas en el entrenamiento de los sujetos, algo especialmente importante en las transiciones entre ellas.

- 1) Interfaz de usuario. Por una parte, el interfaz gráfico guía a los sujetos a

través del experimento, de forma que se activa en verde el recuadro de la izquierda o de la derecha cuando éstos deben pensar en mover su mano izquierda o derecha respectivamente, mientras que en el centro se muestra una letra cuando deben concentrarse en pensar palabras. Las diferentes áreas de la pantalla se colorean a intervalos de quince segundos, desactivándose al finalizar el estado de las mismas. Igualmente, la aplicación muestra un mensaje de espera durante diez segundos para que los colaboradores terminen de acomodarse antes del experimento y otro marcando la finalización del mismo.

- 2) Sistema de acceso a datos cerebrales. Emotiv permite el acceso a los datos brutos capturados sobre el cuero cabelludo, con la salvedad de que aunque la frecuencia de muestreo anunciada es de 2048 Hz, la velocidad de transmisión de la información se limita a 128 veces por segundo, promediándose el valor de las lecturas. Dado que el fabricante distribuye un SDK con funciones que permiten el acceso a los datos obtenidos en tiempo real, el software desarrollado incluye las llamadas pertinentes para establecer la conexión, capturar y almacenar los datos, además de las requeridas para terminar la conexión y gestionar el interfaz gráfico. Finalmente, los datos se guardan en formato de valores separados por comas (*.csv*) utilizados en las etapas posteriores de preprocesamiento, clasificación y selección de características.
9. Cuestionario de evaluación. Al finalizar el experimento, se les pide a los usuarios que rellenen un cuestionario donde se recoge su percepción sobre el experimento.

Entre las preguntas más relevantes que los voluntarios realizan de forma previa al experimento están a) si la prueba es dolorosa o si van a recibir algún tipo de descarga eléctrica, b) la duración total y c) la tasa de acierto mayor alcanzada y la forma de pensar que maximiza el rendimiento. Se informa a los usuarios de que no van a sentir ningún tipo de descarga eléctrica y de que la experiencia no es dolorosa, la duración estimada se sitúa entre los 45 minutos y 1 hora dependiendo del tiempo de descanso (incluyendo la instalación del dispositivo y la explicación del experimento). Así mismo, se enfatiza la relevancia de la capacidad de relajación y concentración para conseguir unos buenos resultados. Además, se reitera la necesidad de ser consistente en los pensamientos asociados a cada tarea, especialmente en las motoras, para que el clasificador aprenda correctamente a distinguir la intención de movimiento. Los datos obtenidos utilizando el procedimiento anterior son:

1. Datos preliminares preprocesados capturados con Emotiv EPOC. Se toman datos de tres usuarios varones y diestros entre los 29 y los 50 años ( $42.67 \pm 11.85$ ).
2. Datos obtenidos con el sistema híbrido Emotiv EPOC - EasyCap en las posiciones BCI Competition. Comprende datos de cinco sujetos varones entre los 32 y los 51 años ( $39.60 \pm 11.28$ ). De este conjunto de datos, sólo se incluyen los tres de mayor tasa de acierto.

3. Datos grabados con el sistema híbrido Emotiv EPOC - EasyCap en las posiciones Emotiv. Incluye datos de cinco sujetos varones entre los 32 y los 51 años ( $39.60 \pm 11.28$ ). De este conjunto de datos sólo se utilizan los tres de mayor tasa de acierto.
4. Datos capturados con Emotiv EPOC para una población de 19 usuarios con edades comprendidas entre los 10 y los 69 años ( $35.4 \pm 14.5$ ), de los cuales 4 son mujeres. Pese a que algunos de ellos están familiarizados con los conceptos de BCI y EEG dados sus ámbitos de estudio e investigación, 15 no han realizado experimentos de imaginación de movimiento previamente. Desafortunadamente, existen problemas informáticos durante la captura de datos de dos de ellos, lo que causa que sus sesiones sean incompletas. Igualmente, cinco voluntarios obtienen resultados alrededor del nivel aleatorio, por lo que son descartados, supusiendo un 29 % del total de recopilaciones de datos realizadas. En definitiva, este conjunto de datos sólo incluye sesiones de 12 colaboradores.

De la muestra total, hay tres usuarios que participan en todos los experimentos. No obstante, dada la diferencia temporal entre las capturas de datos (en el caso de mayor frecuencia éstas se han hecho con meses de diferencia) y la falta de realimentación en el experimento, no se considera la experiencia acumulada como un factor distorsionador de la muestra. Del mismo modo, dos de los colaboradores son zurdos, sin embargo, los datos de uno de ellos se descartan debido a un fallo informático durante su obtención.




Figura 3.3: Distribución de las respuestas de los usuarios a las preguntas de los bloques 2 y 3 del cuestionario realizado después del experimento. La letra B distingue el bloque de preguntas del cuestionario y la Q a la pregunta

A partir de los cuestionarios rellenados de forma posterior al experimento, cuyo formato se incluye en el Apéndice A.1, se obtiene la distribución de las respuestas que presenta la Figura 3.3. Cabe destacar que cuatro colaboradores perciben la colocación del Emotiv EPOC como un procedimiento incómodo (B2Q1) y dos lo consideran molesto durante la realización del experimento (B2Q2). De todas las sugerencias recibidas, casi la mitad tienen que ver con el dispositivo de captura de datos. En concreto se sugieren la facilidad de colocación y la ergonomía como áreas de mejora, incluyendo avances en el acolchado de

los sensores y en la comodidad del dispositivo, que los usuarios identifican como incómodo tras llevarlo cierto tiempo.

El experimento es considerado difícil únicamente por dos usuarios (B3Q1), aunque genera entre un poco y bastante cansancio a 10 de los 19 participantes (B2Q2), y ninguno únicamente a tres de ellos. El tiempo de descanso es adecuado para 16 sujetos y largo para los otros tres (B3Q3) mientras que todos consideran su participación entre satisfactoria y completamente satisfactoria (B3Q4), con nueve considerándola muy satisfactoria y seis completamente. Es decir, todos los colaboradores piensan que han alcanzado un alto rendimiento. No obstante, entre las sugerencias aparecen la posibilidad de acortar las sesiones, el cambio más continuo entre tareas y la inclusión de realimentación. Únicamente un colaborador identifica como mejora la realización del experimento en una sala con mejor insonorización.

Finalmente, las respuestas relacionadas con la tarea que más trabajo les cuesta llevar a cabo son diversas. Concretamente, seis voluntarios consideran que la tarea más difícil es pensar en mover la mano derecha, cinco pensar en mover la mano izquierda y cuatro en encontrar palabras que empiecen por la misma letra. Es interesante que cuatro de colaboradores identifican las transiciones entre estados motores como las tareas más costosas de llevar a cabo, opción no incluida en el cuestionario.

Los resultados obtenidos en relación con el número de usuarios cuyos datos tienen que ser descartados por no superar la probabilidad aleatoria es un fenómeno común dentro del análisis de datos BCI. La literatura denomina dicho fenómeno *BCI illiteracy* y afecta en diferentes experimentos a entre el 15 y el 30 % de los sujetos ([155]), por lo que el 29 % alcanzado en éste queda dentro del rango. Fundamentalmente, el fenómeno recoge la incapacidad de algunos individuos de generar patrones cerebrales detectables para una tecnología de captura particular, como por ejemplo EEG, lo que les impide operar ciertos tipos de sistemas BCI [156]. Este fenómeno se debe a las peculiaridades individuales de la estructura cerebral de cada ser humano que, si bien genera los patrones (en el ejemplo de imaginación de movimiento el sujeto es capaz de controlar sus extremidades), lo hace de una localización alejada del cuero cabelludo, de forma muy tenue o junto a poblaciones de neuronas que presentan una actividad mayor. Por tanto, el entrenamiento de estos usuarios es mayormente irrelevante para la mejora de su capacidad de control del sistema.

## 3.2. Metodología de preprocesamiento

En una primera etapa, la metodología de preprocesamiento aplicada es análoga a la propuesta en el BCI Competition. Así se hace uso una superficie Laplaciana para filtrar espacialmente los potenciales capturados. Este cálculo se realiza a partir de una aproximación basada en un método de diferencias finitas, donde la densidad radial de corriente en cada sensor se estima a partir de la diferencia entre el potencial en el canal de interés y la media ponderada de los potenciales capturados en los otros sensores en función de su distancia.

Una vez completada esta fase, se calcula la PSD en la banda de frecuencias comprendida entre 8 y 30Hz, utilizando una resolución de 2Hz. Los datos se dividen en ventanas de 1




Figura 3.4: Comparación entre las ventanas de Hamming y Hanning

segundo, con un avance basado en la frecuencia de muestreo dividida entre 16 tal y como se realiza en los ficheros de referencia del BCI Competition III dataset V, lo que conlleva un solapamiento entre ventanas del 93.75 %.

El procesamiento más común que se presenta en la literatura para este escenario es la utilización de la PSD a partir del estimador de Welch, basado en la media del solapamiento entre ventanas, y que en Matlab se calcula utilizando función `PWelch` ([127],[157],[158],[17]). Éste incluye por defecto un alisado de la ventana de datos utilizando una ventana de Hamming y un solapamiento entre ventanas del 50 % con el objetivo de calcular la media de los datos. La elección de la misma es consistente con los datos obtenidos en el BCI Competition donde el preprocesamiento de los datos con esta función ofrece valores de tasa de acierto de clasificación muy similares utilizando la arquitectura S-dFasArt [135].

Asimismo, y debido a que en la literatura parece estar extendida la utilización de ventanas de tipo Hanning junto con la función `PWelch`, mientras que ésta implementa por defecto la utilización de una ventana de Hamming, se ha realizado un estudio adicional en el que se calcula el rendimiento utilizando diferentes variantes del estimador de Welch. Del mismo modo, se realizan variaciones utilizando el estimador por cálculo de periodogramas (función `Periodogram` de Matlab). Los resultados obtenidos se presentan más adelante en este capítulo.

Existen dos restricciones fundamentales a tener en cuenta asociadas al experimento para cumplir con las reglas especificadas por el BCI Competition. La primera de ellas limita la cantidad de información máxima para realizar una predicción, no permitiéndose ventanas mayores a un segundo. La segunda establece la velocidad requerida en la respuesta del sistema, establecida en una respuesta cada medio segundo, tal y como se muestra en la Figura 3.5 para las seis primeras predicciones.



Figura 3.5: Restricciones relacionadas con la cantidad de datos máxima para proveer de una salida en el BCI Competition III dataset V aplicadas a los datos capturados Emotiv EPOC

Debido a la diferencia entre las frecuencias de muestreo del dispositivo de grabación original Biosemi Active II (512Hz) y el Emotiv EPOC (128Hz) o Emotiv EPOC - EasyCap (128Hz), el tamaño de las ventanas de procesamiento se reduce a 128 muestras. Del mismo modo, se detalla en la definición del experimento provista por el BCI Competition que la estimación de la PSD se ha de calcular un máximo de 16 veces por segundo pero sólo se pueden utilizar 8 muestras consecutivas para proveer de cada predicción. Es decir, se debe estimar una nueva PSD con las muestras capturadas en el medio segundo previo de datos cada vez que se leen 32 muestras nuevas. Mantener dicho criterio para los datos capturados con Emotiv EPOC supone realizar el procedimiento análogo cada 8 muestras, siempre utilizando el último medio segundo de datos (se detalla como cuadrados más oscuros en la línea de la Predicción 6 en la Figura 3.5). Por tanto, para el cálculo de cada salida se utilizan 8 ventanas de 168 elementos (14 sensores por 12 frecuencias).

### 3.3. Clasificación

La calidad de la señal capturada en cada una de las bases de datos se evalúa utilizando una aproximación cuantitativa, basada en la tasa de acierto de clasificación alcanzada al procesar los datos con un sistema de tipo S-dFasArt para todos los experimentos, cuya metodología se ha detallado en el capítulo anterior. Se elige dicha aproximación porque ya ha mostrado resultados óptimos para los datos del BCI Competition III dataset V ([135]). Como se explica anteriormente, en la construcción del clasificador se emplean tres de las sesiones de datos capturadas para cada usuario. En la arquitectura presentada en la Figura 2.35 se pueden diferenciar seis modelos, creados a partir de la combinación entre aprendizaje y ajuste de parámetros de las tres sesiones de entrenamiento disponibles.

La cuarta sesión se utiliza para comprobar el rendimiento del clasificador. Teniendo en cuenta la restricción anterior en relación con la cantidad de datos máxima para calcular una salida (medio segundo equivalente a 8 vectores de datos) y la arquitectura creada (basada en 6 modelos), se dispone de 48 predicciones. Finalmente, un último módulo ofrece como predicción definitiva aquella más frecuente de entre todas las presentadas.



### 3.3.1. Parámetros de clasificación

Una de las dificultades que conlleva la investigación con datos cerebrales es su variabilidad. Por un lado, pese a que las zonas excitadas son análogas, la estructura cerebral de cada persona es individual, por lo que datos de sujetos diferentes requieren de una parametrización específica. Además, existe variabilidad intra-usuario, ya que al ser la señal cerebral tan pequeña, el estado mental del sujeto condiciona la precisión del clasificador ([159]). Es decir, si un usuario está nervioso o cansado, sus patrones cerebrales son diferentes a cuando está relajado, independientemente de que las acciones se generen en la misma ubicación cerebral. Volviendo al ejemplo que se plantea a los colaboradores realizando el experimento, los comensales del restaurante cambian y éstos pueden ser más o menos ruidosos.

El clasificador SdFasArt se define a partir de una serie de parámetros que permiten adaptar el modelo a cada caso en particular optimizando la precisión del mismo. Entre éstos se puede destacar:

1.  $A_r$  - velocidad a la que crece el nivel de reset. Define la capacidad de la categoría de aprender de la entrada que la activa. Todos los datos presentados en esta tesis doctoral se han calculado para valores de  $A_r$  0.001, 0.002 y 0.003. Éstos se basan en valores eurísticos obtenidos durante el procesamiento de los datos del BCI Competition III Dataset V en [135].
2.  $\sigma$  - modifica el tamaño de la función triangular de activación-pertenencia, definiendo la característica difusa de la categoría de salida.
3.  $A_t$  - velocidad a la que crece el nivel de activación de las neuronas de la red.

La definición del mejor valor de  $\sigma$  y  $A_t$  se basa en un procedimiento de búsqueda por cuadrícula en un hiperplano definido por valores de  $A_t$  entre 1 y 30, y valores singulares de  $\sigma$  desde 0.1 a 0.9, desde 0.01 a 0.09 y desde 0.001 hasta 0.009. Este proceso se repite tres veces para uno de los seis modelos  $s1s2$ ,  $s1s3$ ,  $s2s1$ ,  $s2s3$ ,  $s3s1$ ,  $s3s2$  siguiendo el diagrama representado en la Figura 3.6.

1. Determinar  $A_t$  inicial. El algoritmo parte desde tres puntos diferentes de  $A_t$ : 0.1, 0.05 y 0.5. De este modo se asegura que valores dispares de dicho parámetro son evaluados y, al generar la entrada al hiperplano por tres puntos diferentes, disminuye el impacto que mínimos locales pueden tener en el detenimiento de la búsqueda.
2. Crear vector con  $\sigma = 1, 10, 20$ . El objetivo consiste en orientar el valor  $\sigma$  hacia la valores del mismo que maximizan el acierto.
3. Calcular tasa de acierto. La elección de la mejor combinación de  $\sigma$  y  $A_t$  se basa en la elección de aquel par ofreciendo una tasa de acierto mayor para el modelo  $s_j s_k$  evaluado. Por tanto han de calcularse todas las combinaciones posibles de estos valores según el vector o cuadrícula definidos.
4. Seleccionar  $\sigma$  y  $A_t$  que ofrecen un mejor rendimiento.

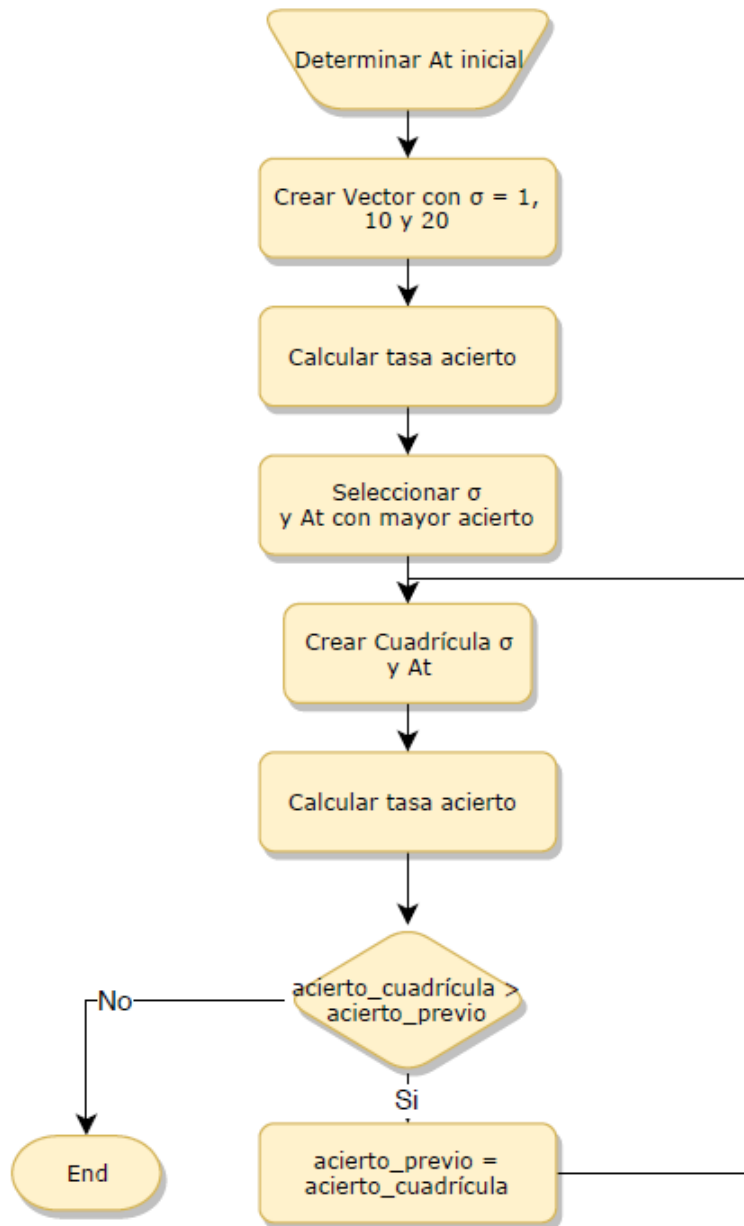


Figura 3.6: Proceso de búsqueda de los valores óptimos de los parámetros  $\sigma$  y  $A_t$  de los modelos S-dFasArt

5. Crear cuadrícula  $\sigma$  y  $A_t$ . El punto del hiperplano seleccionado en la fase anterior se convierte en el centro de la cuadrícula, que se compone como se muestra en la Tabla 3.2.

Tabla 3.2: Definición de los valores de  $\sigma$  y  $A_t$  calculados en cada iteración del algoritmo de búsqueda de parámetros óptimos para el clasificador S-dFasArt

$\sigma-1, A_{t-1}$	$\sigma-1, A_t$	$\sigma-1, A_{t+1}$
$\sigma, A_{t-1}$	$\sigma, A_t$	$\sigma, A_{t+1}$
$\sigma+1, A_{t-1}$	$\sigma+1, A_t$	$\sigma+1, A_{t+1}$

6. Calcular tasa de acierto. Se calcula el acierto de clasificación para cada una de las combinaciones de  $\sigma$  y  $A_t$  y se elige aquélla que ofrece el mayor valor para el modelo.
7.  $\text{Acierto\_cuadrícula} < \text{acierto\_previo}$ . Este punto define el mecanismo de parada del algoritmo. Si el rendimiento alcanzado por los pares de la cuadrícula no es mejor que el que aparece en el centro de la misma, se selecciona éste como máximo.
8.  $\text{Acierto\_previo} < \text{acierto\_cuadrícula}$ . En caso de que el par  $(\sigma, A_t)$  alcance una tasa de acierto mayor a la del anterior centroide, se ubica éste en el centro de una nueva cuadrícula y se repite el proceso actual desde el punto 5.

### 3.4. Resultados

Para determinar la calidad de los datos capturados utilizando Emotiv EPOC se evalúan tres criterios distintos:

1. Se define una nueva categoría denominada "Motor", incluyendo las tareas motoras del experimento: pensar en mover la mano Izquierda- $L$  y la derecha Derecha- $R$ . Entonces, la precisión motora media ( $M_A$ ) se calcula como el número de veces en el que la predicción es correcta para tareas motoras ( $C_M$ ) y no motoras ( $C_P$ ) dividida entre el número total de vectores de la sesión de test ( $V_T$ ):

$$M_A = \frac{C_M + C_P}{V_T} \quad (3.1)$$

2. Las tasas de acierto de Derecha ( $S_D$ ), Izquierda ( $S_I$ ) and Palabra ( $S_P$ ) se obtienen dividiendo el número de veces que el sistema predice correctamente dicha categoría ( $C_X$ ) entre en número de vectores del conjunto de datos para cada categoría ( $V_X$ ). Como ejemplo:

$$S_D = \frac{C_D}{V_D} \quad (3.2)$$

3. Matrices de Confusión. Se utilizan matrices de error donde queda patente el número de veces que un determinado patrón es confundido por otro. Cada columna de la matriz presenta las instancias en la categoría predicha mientras que las filas muestran

las instancias en la clase real. Una de las ventajas de esta herramienta es la visibilidad dada a las confusiones entre dos clases.

Éstos cálculos se repiten sobre los seis conjuntos de datos definidos en 3.1.1. Además, y con el objetivo de permitir facilitar la comprensión de los resultados presentados, se han añadido los resultados de las mismas tanto en los datos presentados en este capítulo como en los otros calculados, que se adjuntan en los apéndices de este trabajo.

### 3.4.1. Datos preprocesados BCI Competition III dataset V

En primer lugar se presenta en la Tabla 3.3 la precisión en la predicción alcanzada por el clasificador S-dFasArt utilizando el conjunto de datos preprocesados provisto en el BCI Competition III dataset V, que se establece como base para comparaciones posteriores con las otras aproximaciones enumeradas. En total se incluyen datos de 8 sensores, en las posiciones C3, Cz, C4, CP1, CP2, P3, Pz y P4, situadas sobre la zona centro-parietal del cerebro.

Se puede apreciar en la misma que mientras los Sujetos 1 y 2 presentan tasas de acierto por encima del 80 %, el rendimiento global alcanzado para el Sujeto 3 muestra un nivel de precisión casi 30 puntos peor que el alcanzado para el Sujeto 1 y 25 puntos más bajo que el mostrado para el Sujeto 2. Esta diferencia es la mayor encontrada entre diferentes sujetos para todos los conjuntos de datos, tal y como se comprueba en los apartados siguientes.

Tabla 3.3: Niveles de precisión alcanzados para los datos preprocesados BCI Competition III dataset V mostrados como %

	Tasa de acierto (%)				
	Global	Motor	Derecha	Izquierda	Palabra
BCIComp Sujeto 1	87.67	92.47	78.91	92.31	90.56
BCIComp Sujeto 2	82.26	88.02	81.25	77.78	85.71
BCIComp Sujeto 3	58.72	75.23	73.97	24.00	80.00
<b>Media</b>	76.22	85.24	78.04	64.70	85.42

La Tabla 3.4 muestra una marcada relación entre la precisión en la predicción de la tarea Izquierda - *I* y la global del sistema. Para el Sujeto 1, que alcanza el mayor rendimiento, el clasificador es capaz de predecir correctamente 120 de las 130 ocurrencias de la clase (92.31 %). Por contra, para el Sujeto 2 sólo predice acertadamente 84 de 108 (77.78 %), mientras que para el 3 se reduce esta cifra a 36 de 150 (24 %). Para las otras dos tareas (Derecha - *D* y Palabra - *P*) los resultados son más homogéneos, si bien la predicción de *P* presenta claramente un mejor acierto para todos los usuarios. De hecho, es la tarea predicha de un modo más preciso por el método de clasificación.

Tabla 3.4: Matriz de confusión para los datos preprocesados BCI Competition III dataset V

<b>BCIComp Sujeto 1</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	120	5	5
Real Derecha	16	101	11
Real Palabra	10	7	163
<b>BCIComp Sujeto 2</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	84	21	3
Real Derecha	4	117	23
Real Palabra	16	10	156
<b>BCIComp Sujeto 3</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	36	59	55
Real Derecha	13	108	25
Real Palabra	14	14	112

### 3.4.2. Datos BCI Competition III dataset V - Posiciones Emotiv

Además de los datos preprocesados, el BCI Competition III dataset V publicó las lecturas de los potenciales eléctricos capturados sobre el cuero cabelludo de los diferentes sujetos para cada sesión. La grabación de los mismos se realizó con un equipo Biosemi de 32 canales en las posiciones FP1, AF3, F7, F3, FC1, FC5, T7, C3, CP1, CP5, P7, P3, Pz, PO3, O1, Oz, O2, PO4, P4, P8, CP6, CP2, C4, T8, FC6, FC2, F4, F8, AF4, Fp2, Fz, Cz.

Dado que las posiciones cubiertas por el Emotiv EPOC se encuentran entre las anteriores (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4), se extraen los datos capturados en las posiciones disponibles en el Emotiv EPOC y se replican los cálculos realizados durante la etapa de preprocesado.

Tabla 3.5: Niveles de precisión alcanzados para los datos BCI Competition III dataset V seleccionando las posiciones disponibles en Emotiv EPOC mostrados como %

<b>Tasa de acierto (%)</b>					
	<b>Global</b>	<b>Motor</b>	<b>Derecha</b>	<b>Izquierda</b>	<b>Palabra</b>
BCIEpoc Sujeto 1	63.40	83.19	93.57	19.72	73.94
BCIEpoc Sujeto 2	59.07	68.35	46.25	25.83	90.21
BCIEpoc Sujeto 3	42.23	59.45	32.72	26.58	67.95
<b>Media</b>	54.90	70.33	57.51	24.04	77.37

Tabla 3.6: Matriz de confusión para los datos BCI Competition III dataset V seleccionando las posiciones disponibles en Emotiv EPOC

<b>BCIEpoc Sujeto 1</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	28	92	22
Real Derecha	1	131	8
Real Palabra	4	45	139
<b>BCIEpoc Sujeto 2</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	31	29	60
Real Derecha	15	74	71
Real Palabra	3	16	175
<b>BCIEpoc Emo Sujeto 3</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	42	45	71
Real Derecha	37	53	72
Real Palabra	20	30	106

Como muestra la Tabla 3.5 la tasa de acierto permanece por encima del nivel de oportunidad (33 %). Igualmente, se puede observar que la tarea predicha con mayor acierto es en media Palabra -  $P$ , con un 77.37 %. Los patrones motor  $M$  se mantienen en un rango de acierto por encima del 70 %, si bien las predicciones motoras individuales Izquierda -  $I$  y Derecha -  $D$  muestran valores bastante más discretos, especialmente para  $I$  (24.04 %). Igualmente, también se demuestra la existencia de algunas categorías que, para cada usuario, se clasifican de una forma más precisa:  $D$  para el Sujeto 1 y  $P$  para los Sujetos 2 y 3, duplicando el acierto en estos dos últimos casos de la segunda tarea mejor predicha [160].

La Tabla 3.6 revela la tendencia a predecir Derecha -  $D$  del clasificador dentro de las tareas motoras para el Sujeto 1, algo que se repite en menor medida para el resto. Además, se puede observar la robustez general de  $P$  para todos los usuarios, y cómo la confusión más común para esta tarea es  $D$ .

### 3.4.3. Datos capturados con Emotiv EPOC

El criterio para nombrar a los diferentes usuarios se basa en el establecido por BCI Competition, que además coincide con el ranking asociado a la precisión del sistema presentado en [135], donde el Sujeto 1 es para el que se obtiene la mejor tasa de acierto seguido del 2, siendo el Sujeto 3 el que muestra un acierto menor. De este modo se facilita la comparacion de los resultados finales. Esta base de datos se identifica para análisis posteriores como EmoEpoc.

Como se muestra en la Tabla 3.7, la tasa de acierto alcanzada vuelve a estar por encima del nivel de oportunidad (33 %) para todos los usuarios. Así mismo, no existen

Tabla 3.7: Niveles de precisión alcanzados para los datos capturados con Emotiv EPOC mostrados como %

	Tasa de acierto (%)				
	Global	Motor	Derecha	Izquierda	Palabra
EmoEpoc Sujeto 1	69.04	82.22	41.61	72.63	92.00
EmoEpoc Sujeto 2	63.50	82.51	49.43	93.79	50.00
EmoEpoc Sujeto 3	55.29	80.35	47.40	53.10	66.90
<b>Media</b>	62.61	81.69	46.15	73.17	69.63

Tabla 3.8: Matriz de confusión para los datos capturados con Emotiv EPOC

EmoEpoc Sujeto 1			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	130	25	24
Real Derecha	38	62	49
Real Palabra	8	4	138
EmoEpoc Sujeto 2			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	136	2	7
Real Derecha	86	86	2
Real Palabra	56	16	72
EmoEpoc Sujeto 3			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	77	47	21
Real Derecha	69	82	22
Real Palabra	37	11	97

diferencias significativas en la precisión prediciendo la tarea Motor entre los usuarios, mostrando un valor por encima del 80 % en todos los casos. A partir de estos datos se puede apreciar cómo el usuario que consigue una mayor tasa de acierto es también el único que tiene experiencia previa en el uso de sistemas EEG, el Sujeto 1. Sin embargo, la diferencia entre los resultados no es tan abrupta como la encontrada para el conjunto de datos del BCI Competition. Lo mismo ocurre con Derecha -  $D$ , cuya diferencia se sitúa entre 41.61 % y 49.42 %. Por otra parte, Izquierda -  $I$  y Palabra -  $P$  sí que presentan una variación importante entre los diferentes usuarios, la primera en un rango entre el 53.10 % del Sujeto 3 y el 93.79 % del Sujeto 2 y la segunda entre el 50 % del Sujeto 2 y el 92 % del Sujeto 1.

Desafortunadamente, no es posible establecer ningún patrón del análisis de las tres columnas, a parte de un mayor carácter discriminante de un pensamiento específico para

cada usuario:  $P$  para los Sujetos 1 y 3 e  $I$  para el Sujeto 2.

Lo que se puede observar en la Tabla 3.8 es un alto nivel de confusiones debidas a la errónea predicción del patrón  $D$  como  $I$  para todos los sujetos. De hecho, se puede generalizar una correlación entre éstas dado que ocurren con mayor regularidad que Real  $D$  o  $I$  prediciendo  $P$  o Real  $P$  predicha como  $D$  o  $I$ . En resumen, existe un nivel más elevado de error entre las tareas motoras  $I$  y  $D$  que entre éstas y la tarea  $P$ . Por el contrario, algunas confusiones aparecen en muy raras ocasiones como por ejemplo  $P$  predicho como  $D$  para el Sujeto 2. Además, es interesante resaltar que  $P$  es también la tarea predicha de un modo más preciso para los Sujetos 1 y 3, mostrando el mayor valor en sus matrices de confusión [160].

#### 3.4.4. Datos capturados con Emotiv EasyCap - Posiciones BCI Competition

La flexilidad que el sistema híbrido Emotiv EasyCap aporta permite la realización de un estudio propio incluyendo las posiciones de la base de datos preprocesada del BCI Competition III Dataset V (posiciones C3, Cz, C4, CP1, CP2, P3, Pz y P4). Siguiendo el criterio expuesto anteriormente, los colaboradores se ordenan en función de la precisión alcanzada por el clasificador.

Tabla 3.9: Niveles de precisión alcanzados para los datos capturados con Emotiv EasyCap en las posiciones de los datos preprocesados del BCI Competition mostrados como %

	Tasa de acierto (%)				
	Global	Motor	Derecha	Izquierda	Palabra
EasyBCI Sujeto 1	75.52	91.42	67.11	71.51	88.67
EasyBCI Sujeto 2	65.48	80.13	60.40	49.16	90.00
EasyBCI Sujeto 3	58.58	82.01	45.64	59.78	70.00
<b>Media</b>	66.53	84.52	57.72	60.15	82.89

La Tabla 3.9 muestra como Palabra -  $P$  es la tarea para la que se consigue una mejor tasa de acierto en todos los usuarios, si bien un valor menor de la misma también penaliza el acierto global para el Sujeto 3. De hecho, los valores de acierto entre Motor -  $M$  y Palabra -  $P$  son homogéneos, siendo la diferencia menor entre dichos valores 2.75 puntos para el Sujeto 1 en el mejor de los casos y 12.01 puntos para el Sujeto 3 en el peor. Por tanto, se puede determinar que el sistema predice tan bien tareas Motoras -  $M$  como Palabra -  $P$  para el Sujeto 1, pero que esta capacidad se va perdiendo para el resto, si bien la diferencia no es demasiado amplia.

Centrando ahora la atención en detección de la intención de movimiento, se puede apreciar una tendencia análoga a la de Motor -  $M$  y Palabra -  $P$ . En este caso, para el Sujeto 1, sólo hay una diferencia de 4.4 puntos entre la capacidad de predecir Izquierda -  $I$  y Derecha -  $D$ , que pasa a 11.24 para el Sujeto 2 y 14.14 para el Sujeto 3.



Tabla 3.10: Matriz de confusión para los datos capturados con Emotiv EPOC Easycap en las posiciones de los datos preprocesados del BCI Competition

<b>EasyBCI Sujeto 1</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	128	44	7
Real Derecha	32	100	17
Real Palabra	5	12	133
<b>EasyBCI Sujeto 2</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	88	40	51
Real Derecha	30	90	29
Real Palabra	9	6	135
<b>EasyBCI Sujeto 3</b>			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	107	51	21
Real Derecha	61	68	20
Real Palabra	30	15	105

Finalmente, resulta destacable que el acierto general del sistema está en el rango de la segunda tarea mejor predicha para cada usuario. Por ejemplo, para el Sujeto 1 la segunda mejor tarea es *I* con un 71.51 %, que está en el nivel de los 75.52 % que se alcanzan de forma global para el sujeto. Ésto se repite para el Sujeto 2 con *D* en un 60.40 % y el acierto global en un 65.48 % y para el Sujeto 3 con *I* en un 59.78 % con un acierto general del 58.58 %.

En cuanto a las confusiones, para el Sujeto 1 se aprecia cómo las equivocaciones en la predicción del clasificador ofrecen con mayor frecuencia el valor *D* que cualquiera de los otros. Sin embargo, esta tendencia no se mantiene para los Sujetos 2 y 3, los cuales únicamente muestran como patrón destacable el hecho de que los fallos en la predicción de las tareas *D* y *P* llevan al clasificador a predecir Izquierda - *I* en el mayor número de casos. Respecto a las tendencias en cuanto a las predicciones realizadas por el clasificador, se puede apreciar como para el Sujeto 1 éstas se distribuyen de forma homogénea, mientras que para el Sujeto 2 la tarea más predicha es *P* (que obtiene el mayor porcentaje de acierto) y para el Sujeto 3 es *I*, si bien en este caso no se traduce en la tarea con mayor acierto para el usuario.

#### 3.4.5. Datos capturados con Emotiv EasyCap - Posiciones Emotiv

Al igual que en el caso anterior, Emotiv EasyCap se utiliza para tomar datos que puedan compararse con aquellos capturados con el propio EPOC. El objetivo fundamental de esta base de datos es estudiar el efecto de la diferencia en la tecnología de captura de la señal entre Emotiv EPOC y el sistema híbrido.

Tabla 3.11: Niveles de precisión alcanzados para los datos capturados con Emotiv EPOC EasyCap en las posiciones estándar Emotiv EPOC mostrados como %

	Tasa de acierto (%)				
	Global	Motor	Derecha	Izquierda	Palabra
EasyEpoc Sujeto 1	56.07	83.47	15.44	93.30	52.00
EasyEpoc Sujeto 2	54.81	72.59	38.26	58.66	66.67
EasyEpoc Sujeto 3	47.07	57.53	18.12	41.34	82.67
<b>Media</b>	52.65	71.20	23.94	64.43	67.11

Tabla 3.12: Matriz de confusión para los datos capturados con Emotiv EPOC EasyCap en las posiciones de los datos preprocesados del BCI Competition

EasyEpoc Sujeto 1			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	167	11	1
Real Derecha	120	23	6
Real Palabra	47	25	78
EasyEpoc Sujeto 2			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	105	51	23
Real Derecha	34	57	58
Real Palabra	30	20	100
EasyEpoc Sujeto 3			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	74	30	75
Real Derecha	20	27	102
Real Palabra	17	9	124

Ordenando los Sujetos en torno al acierto de clasificación alcanzado se puede apreciar que la diferencia entre el mayor y el menor de los rendimientos conseguidos se sitúa en 9 puntos (Tabla 3.11). Sin embargo, no se puede determinar ninguna tendencia dentro de las tasas de acierto de las tareas individuales que se pueda relacionar con ésta.

Lo que sí resulta aparente a partir de las matrices de confusión presentadas es que tanto para el Sujeto 1 como para el 3 el clasificador tiende a predecir una sola clase de una forma clara. Por ejemplo, para el Sujeto 1 se puede apreciar que el sistema predice Izquierda - *I* en casi el 70 % de las ocasiones, alcanzando más del 90 % de acierto para dicha tarea, mientras que para el Sujeto 3 esta tendencia se repite con Palabra - *P* en casi un 63 % de las predicciones, permitiendo a ésta llegar a un acierto del 82.67 %. El Sujeto 2 muestra *P* en un porcentaje cercano al 38 %, alcanzando una precisión del 66.67 %.

### 3.4.6. Datos capturados con Emotiv EPOC - Base de datos extendida

La base de datos que se presenta a continuación permite identificar patrones y tendencias en los datos capturados con Emotiv EPOC. De este modo, es posible determinar con mayor soporte empírico si ciertas peculiaridades encontradas en experimentos previos se pueden generalizar. Al igual que en apartados anteriores, y con el objetivo de facilitar el análisis, la nomenclatura seguida asocia el Sujeto 1 a la mayor precisión y al 12 la más reducida.

Tabla 3.13: Niveles de precisión alcanzados para los datos capturados con Emotiv EPOC de la base de datos extendida mostrados como %. En **verde**, **naranja** y **rojo** destacan los usuarios para los que se alcanzaron precisiones por encima del 60 %, entre el 50 % y el 60 % y menores al 50 % respectivamente. En **azul** se resalta la tarea mejor predicha. En **magenta** se muestra el acierto mínimo y medio de la tarea motora, mientras que en **azul claro** se han señalado las tasas de medias de acierto para las tareas Derecha - *D* e Izquierda - *I* y en **violeta** la media de la diferencia en el acierto de los estados motores

	Tasa de acierto (%)						
	Global	Motor	Derecha	Izquierda	Palabra	Der-Izq	Mot-Pal
EmoExt S1	67.57	75.73	40.67	73.74	87.25	33.07	11.52
EmoExt S2	62.97	81.17	38.93	62.01	88.00	23.08	6.83
EmoExt S3	62.55	89.94	44.30	69.83	72.00	25.53	6.27
EmoExt S4	61.09	77.62	41.61	77.09	61.33	35.48	16.29
EmoExt S5	60.67	75.73	47.65	53.63	82.00	5.98	6.27
EmoExt S6	57.95	77.82	49.72	59.73	66.00	10.01	11.82
EmoExt S7	55.02	73.01	13.42	82.12	64.00	68.70	9.01
EmoExt S8	53.56	76.99	4.76	94.48	52.00	89.72	24.99
EmoExt S9	52.72	79.71	5.37	72.63	76.00	67.26	3.71
EmoExt S10	51.67	64.44	12.67	54.44	87.84	41.77	23.4
EmoExt S11	50.00	72.38	80.54	43.02	28.00	37.52	44.38
EmoExt S12	48.12	65.27	9.40	71.51	58.67	62.11	6.6
<b>Media</b>	56.99	75.82	32.42	67.85	68.59	41.67	15.23
<b>DesvStd</b>	6.03	6.82	23.28	14.05	17.69	25.45	11.45
<b>Máximo</b>	67.57	89.94	80.54	94.48	87.84	89.72	44.38
<b>Mínimo</b>	48.12	64.44	4.76	43.02	28.00	5.98	3.71

En primer lugar, se ha de destacar que no se encuentra una relación directa entre el acierto para una tarea específica y el rendimiento general del sistema. Se puede apreciar cómo Palabra - *P* es la tarea predicha con mayor precisión para siete de los 12 sujetos de la muestra (en **azul** en la Tabla 3.13), siendo las siguientes Izquierda - *I* con cuatro y Derecha - *D* con sólo uno de los usuarios. Resulta también destacable que el acierto de las tareas Motor - *M* se sitúa siempre por encima del **64.44 %**, con un valor medio del **75.82 %**, lo que implica que el sistema es capaz de distinguir el pensamiento Motor - *M* de Palabra

Tabla 3.14: Niveles de precisión alcanzados por los 5 mejores usuarios de la base de datos extendida Emotiv EPOC mostrados como %. En azul se distingue la tarea cuya predicción alcanzó un acierto mayor para cada sujeto, en magenta se muestra el acierto mínimo y medio de la tarea motora, mientras que en violeta la media de la diferencia en el acierto de los estados motores

	Tasa de acierto (%)						
	Global	Motor	Derecha	Izquierda	Palabra	Der-Izq	Mot-Pal
EmoExt S1	67.57	75.73	40.67	73.74	87.25	33.07	11.52
EmoExt S2	62.97	81.17	38.93	62.01	88.00	23.08	6.83
EmoExt S3	62.55	89.94	44.30	69.83	72.00	25.53	6.27
EmoExt S4	61.09	77.62	41.61	77.09	61.33	35.48	16.29
EmoExt S5	60.67	75.73	47.65	53.63	82.00	5.98	6.27
<b>Media</b>	62.97	80.04	42.63	67.26	78.12	24.63	11.77
<b>DesvStd</b>	2.75	5.96	3.41	9.47	11.35	25.45	11.45
<b>Máximo</b>	67.57	89.94	47.65	77.09	88.00	35.48	17.94
<b>Mínimo</b>	60.67	75.73	38.93	53.63	61.33	23.08	6.27

-  $P$  de una forma bastante precisa.

Si bien las tareas motoras en conjunto se predicen mejor que Palabra -  $P$  para siete de los 12 casos posibles, se comprueba que la distribución del acierto entre Izquierda -  $I$  y Derecha -  $D$  presenta valores especialmente heterogéneos para tres casos (Sujetos 7, 8 y 12). Igualmente, resulta contradictorio que para una población de 11 usuarios diestros y uno zurdo, Izquierda -  $I$  sea la tarea motora más acertada por 11 de los 12 colaboradores y, exceptuando los Sujetos 5 y 6, por un amplio margen de diferencia. Además, con un valor de precisión medio del 67.85 % que duplica el valor obtenido para de Derecha -  $D$ , que se establece en un 32.42 %.

Reduciendo la muestra a los cinco colaboradores que alcanzan una mayor tasa de acierto (Tabla 3.14) se observan unos pequeños ajustes en las precisiones medias que no invalidan ninguna de las premisas establecidas para el modelo general. En media, la tarea motora continua distinguiéndose de forma efectiva en un 80.04 % de los casos con un mínimo en 75.73 %, mientras que Palabra -  $P$  es la tarea más acertada en cuatro de los cinco usuarios, lo que supone un 80 % de los sujetos.

No obstante, es destacable que los individuos que presentan una distinción efectiva de una de las tareas motoras muy por encima de la otra quedan fuera de este conjunto. De hecho, se puede apreciar que los resultados son más homogéneos para los cinco mejores usuarios, descendiendo el valor medio de la diferencia entre el acierto de Izquierda -  $I$  y Derecha -  $D$  del 41.67 % al 24.63 %.

Las Figuras 3.7 y 3.8 son una representación gráfica resumen de las matrices de confusión calculadas para los sujetos de esta base de datos. Examinándolas con detenimiento se puede observar que la tarea Izquierda -  $I$  se confunde mayoritariamente con Palabra -




Figura 3.7: Distribución de las confusiones para las tareas motoras Izquierda - *I* y Derecha - *D*. Datos EmoExt




Figura 3.8: Distribución de las confusiones para la tarea Palabra - *P*. Datos EmoExt

*P* en el 66 % de los usuarios, porcentaje que alcanza el 80 % para los cinco voluntarios con un acierto por encima del 60 % y que va descendiendo hasta el 50 % para el conjunto de datos consiguiendo una menor precisión.

Respecto a Derecha - *D*, ésta tiende a confundirse mayoritariamente con Izquierda - *I*, desde un 75 % para el conjunto de todos los usuarios hasta la totalidad cuando el rendimiento máximo alcanzado se encuentra por debajo del 50 %. Este mismo comportamiento se observa en la Figura 3.8, donde las confusiones para la tarea Palabra - *P* llevan asociadas predecir Izquierda - *I* para la amplia mayoría de usuarios. Por tanto, queda clara la inclinación del sistema a predecir Izquierda - *I* por encima de cualquier otra opción. Como segunda salida presentada con mayor frecuencia se sitúa Palabra - *P* y por último, el menor número de predicciones se muestra para la tarea predecir Derecha - *D*.

La Figura 3.9 pretende mostrar las individualidades de cada usuario para la sesión 4, que sirve para establecer el acierto conseguido por el sistema para cada estado. Se desea destacar que las etiquetas de los datos de la cuarta sesión (el objetivo), sólo se utilizan en representaciones gráficas y con el fin de calcular la tasa de acierto de clasificación de cada tarea.



Figura 3.9: Representación gráfica de los resultados de la clasificación en función del la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra - *P*

Las salidas más comunes para todos los sujetos son Izquierda - *I* y Palabra - *P*, hecho

acentuado a medida que la tasa de acierto de clasificación va decreciendo. En consonancia con el dato anterior, se puede observar que hay ciertos estados que se predicen erróneamente casi la totalidad de los 15 segundos, sobre todo la tarea Derecha -  $D$  para los Sujetos del 7 al 12.

### 3.4.7. Efecto de la velocidad de reset $A_r$ en el acierto de clasificación

La velocidad de reset es uno de los parámetros que permite adaptar el clasificador S-dFasArt a las características peculiares de los datos maximizando así el rendimiento del sistema. Con el objetivo de determinar el valor de  $A_r$  que permite una mejor generalización, se repiten los procesos de clasificación para los valores 0.001, 0.002 y 0.003 (Apéndice G). La Tabla 3.15 incluye el valor del parámetro  $A_r$  que ofrece los resultados máximos de clasificación.

Tabla 3.15: Niveles de precisión alcanzados utilizando datos capturados con Emotiv EPOC de la base de datos extendida mostrados como % - Valor de  $A_r$  que maximiza el resultado. Los resultados en verde destacan a los usuarios cuyos datos se han procesado con  $A_r = 0.001$ , los de color azul muestran aquellos procesados con  $A_r = 0.002$  y los resaltados en violeta a los basados en  $A_r = 0.003$

	Tasa de acierto (%)					
	Global	Motor	Derecha	Izquierda	Palabra	$A_r$
EmoExt S1	67.57	75.73	40.67	73.74	87.25	0.002
EmoExt S2	62.97	81.17	38.93	62.01	88.00	0.001
EmoExt S3	62.55	89.94	44.30	69.83	72.00	0.002
EmoExt S4	61.09	77.62	41.61	77.09	61.33	0.002
EmoExt S5	60.67	75.73	47.65	53.63	82.00	0.001
EmoExt S6	57.95	77.82	49.72	59.73	66.00	0.001
EmoExt S7	55.02	73.01	13.42	82.12	64.00	0.002
EmoExt S8	53.56	76.99	4.76	94.48	52.00	0.002
EmoExt S9	52.72	79.71	5.37	72.63	76.00	0.003
EmoExt S10	51.67	64.44	12.67	54.44	87.84	0.003
EmoExt S11	50.00	72.38	80.54	43.02	28.00	0.002
EmoExt S12	48.12	65.27	9.40	71.51	58.67	0.002

Como se puede apreciar, el valor de  $A_r = 0.002$  aparece con mayor frecuencia, proporcionando la mejor tasa de acierto para siete de los 12 sujetos. Además, se encuentra dos veces entre los tres primeros colaboradores (66 %) y tres entre los cinco (60 %). Por tanto, y con el objetivo de evaluar las desviaciones entre dicho valor y los máximos conseguidos, se ha elaborado la Tabla 3.16, que muestra los usuarios ordenados de mayor a menor tasa de acierto para  $A_r=0.002$ .

En este caso no se encuentran variaciones importantes en la tasa de acierto global para los Sujetos 1 (0.21 %), 6 (1.46 %) y 9 (1.88 %). Sin embargo, el acierto máximo para

Tabla 3.16: Niveles de precisión alcanzados utilizando datos capturados con Emotiv EPOC de la base de datos extendida mostrados como % utilizando  $A_r=0.002$ . Los sujetos en **naranja** son aquéllos cuya precisión varía respecto a la original. En **verde** destacan los usuarios que ascienden en el ranking y en **rojo** los que descienden. En **azul** se resalta la tarea mejor predicha. En **magenta** se muestra el acierto mínimo y medio de la tarea motora, mientras que en **azul claro** se han señalado las tasas de medias de acierto para las tareas Derecha -  $D$  e Izquierda -  $I$  y en **violeta** la media de la diferencia en el acierto de los estados motores

	Tasa de acierto (%)						
	Global	Motor	Derecha	Izquierda	Palabra	Der-Izq	Mot-Pal
EmoExt S1	67.57	75.73	40.67	73.74	87.25	33.07	11.52
EmoExt S2	62.76	75.31	27.52	70.39	88.67	42.87	13.36
EmoExt S3	62.55	89.94	44.30	69.83	72.00	25.53	6.27
EmoExt S4	61.09	77.62	41.61	77.09	61.33	35.48	16.29
EmoExt S6	56.49	79.71	41.90	61.74	68.74	19.84	10.97
EmoExt S7	55.02	73.01	13.42	82.12	64.00	68.70	9.01
EmoExt S8	53.56	76.99	4.76	94.48	52.00	89.72	24.99
EmoExt S9	50.84	78.87	7.38	67.6	74.00	60.22	4.87
EmoExt S11	50.00	72.38	80.54	43.02	28.00	37.52	44.38
EmoExt S5	49.79	65.69	26.85	40.22	84.00	13.37	18.31
EmoExt S12	48.12	65.27	9.40	71.51	58.67	62.11	6.6
EmoExt S10	45.19	66.32	10.67	56.67	66.22	46.00	0.10
<b>Media</b>	55.25	74.74	29.09	67.37	67.07	44.54	14.86
<b>Máximo</b>	67.57	89.94	80.54	94.48	88.67	89.72	44.38
<b>Mínimo</b>	45.19	65.27	4.76	40.22	28.00	13.37	0.10

el Sujeto 5 desciende un 10.88 % y el del Sujeto 10 un 6.48 %. En resumen, para datos asociados a tasas de acierto altas el cambio en el valor del  $A_r$  proporciona resultados que se pueden considerar marginalmente distintos. Algo que no ocurre al disminuir la calidad de los datos.

Asimismo, utilizar  $A_r=0.002$  provoca un decremento de la precisión media del sistema desde el 56.99 % hasta el 55.25 % (-1.74 puntos), con una diferencia más acentuada en la tarea predecir Derecha -  $D$ , cuyo acierto medio se reduce desde el 32.42 % al 29.09 %. Esto hace que la diferencia media entre las tareas motoras predecir Izquierda -  $I$  y predecir Derecha -  $D$  aumente desde el 41.67 % al 44.54 %. No obstante, la tarea mejor predicha (resaltada en azul) no cambia para ninguno de los colaboradores del experimento.

### 3.4.8. Efecto del cálculo de la PSD en el acierto de clasificación

En la literatura relacionada con la imaginación de movimiento es común que el pre-procesado de los datos incluya el cálculo de la densidad espectral de potencia de la señal



Tabla 3.17: Niveles de precisión alcanzados aplicando diferentes aproximaciones al procesamiento de la PSD. Se utilizan datos capturados con Emotiv EPOC de la base de datos extendida y un valor de  $A_r = 0.002$ . Para cada sujeto se ha marcado el valor máximo de precisión en verde y el segundo mayor en naranja

	Tasa de acierto (%)					
	PWelch 50 % Overlap	PWelch No Overlap	Periodogram	Periodogram	PWelch 50 % Overlap	PWelch No Overlap
	Hamming	Hamming	Hamming	Hanning	Hanning	Hanning
EmoExt S1	67.57	65.27	46.44	47.49	47.49	47.49
EmoExt S2	62.76	58.62	50.86	53.66	53.97	51.46
EmoExt S3	62.55	50.63	50.21	56.07	56.07	56.07
EmoExt S4	61.09	53.77	44.98	45.19	45.19	45.19
EmoExt S6	56.49	54.21	45.57	52.05	45.61	41.00
EmoExt S7	55.02	50.63	28.66	30.75	30.75	30.75
EmoExt S8	53.56	29.08	36.19	37.03	37.03	37.03
EmoExt S9	50.84	47.70	35.98	32.43	32.43	32.43
EmoExt S11	50.00	37.66	49.58	41.84	41.84	41.84
EmoExt S5	49.79	35.15	48.33	46.86	46.86	46.86
EmoExt S12	48.12	31.80	37.03	33.89	33.89	33.89
EmoExt S10	45.19	36.82	25.31	42.26	42.26	42.26
Media	54.57	44.79	40.75	42.35	41.77	41.35

capturada, fundamentalmente utilizando el estimador de Welch. Sin embargo, no se han encontrado estudios que establezcan la bondad de ninguna aproximación sobre el resto. Además, incluso utilizando la misma aproximación existen variantes que condicionan los resultados finales.

La Tabla 3.17 muestra el rendimiento que el sistema alcanza preprocesando los datos de seis modos distintos para un valor de  $A_r = 0.002$ . Resulta evidente que la combinación óptima de parámetros para el cálculo de la PSD debe fundamentarse en la aproximación de Welch, con un solapamiento del 50 % entre ventanas y un alisado a partir de una ventana de Hamming. También es destacable que en segundo lugar se aparece de nuevo la aproximación de Welch combinada con una ventana de Hamming, en este caso sin solapamiento. No obstante, esta segunda aproximación se encuentra casi 10 puntos por debajo en media, lo que se traduce en alrededor de un 18 % menos de rendimiento. Del segundo valor de acierto a los restantes la diferencia media se reduce, situándose en torno a tres puntos (7 %).

Finalmente, resulta también indicativo el efecto sobre los resultados que muestra la utilización de una ventana de tipo Hanning. En estos casos se puede apreciar que los resultados finales son idénticos independientemente de los otros parámetros del cálculo de la PSD para 10 de los 12 colaboradores, lo que es sin duda un resultado muy revelador en cuanto define claramente la influencia que presenta la utilización este tipo de ventana en el procesamiento.

El Apéndice H incluye tanto información gráfica acerca de los resultados como las matrices de confusión para cada sujeto del estudio.

### 3.4.9. Efecto de la realimentación en el acierto de clasificación

Uno de los condicionantes del experimento realizado es la falta de realimentación, que impide a los usuarios conocer si su desempeño es satisfactorio mientras realizan la prueba. Dados resultados alentadores en la literatura como el presentado en [161], se incluye una evaluación del rendimiento en estos casos limitado a un sólo voluntario, que realiza nueve capturas de datos en dos bloques temporales. En primer lugar, la aplicación desarrollada se modifica para mostrar la tarea predicha por el sistema, para ello se añade un nuevo panel al interfaz gráfico denominado “Está Pensando En”, que incluye una serie de recuadros bajo la tarea objetivo que indican tanto el valor calculado por el sistema como la intensidad del mismo (Figura 3.10).

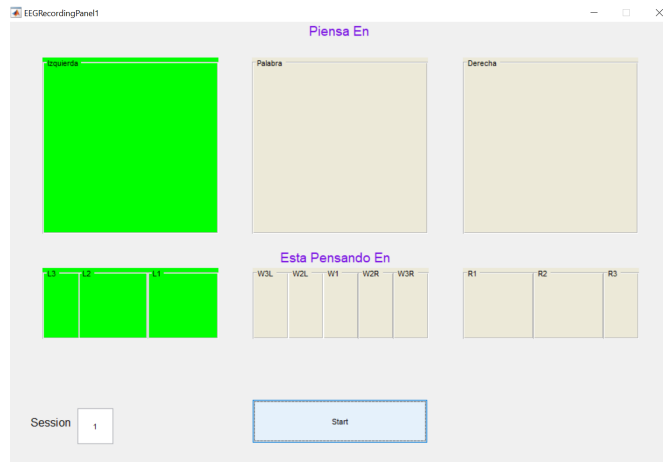


Figura 3.10: Interfaz gráfico de la aplicación de captura de datos con realimentación

Los cuadros se rellenan en función del número de predicciones asociados a la tarea ganadora propuestos por los seis modelos de la arquitectura S-dFasArt. Teniendo en cuenta que cada medio segundo existen 48 predicciones disponibles globalmente, se establece en 21 predicciones el umbral para rellenar los dos cuadros y en 30 para rellenar los tres. Por ejemplo, en la Figura 3.10 se muestra una operativa en la que el sistema propone al usuario pensar en la tarea Izquierda - *I* y los modelos S-dFasArt han generado esa misma salida en al menos 30 predicciones de las 48.

Los resultados mostrados en la Tabla 3.18 se basan en la interacción de un sólo usuario con el sistema utilizando Emotiv EPOC en dos diferentes fases. Las capturas de datos se identifican por su diferencia temporal con la captura de base en días. Por ejemplo, para la Prueba 1, la primera captura después de la de base se realiza al día siguiente y la segunda tres días después de la inicial.

El acierto alcanzado debe compararse con el umbral de los mostrados para las bases

Tabla 3.18: Datos capturados con Emotiv EPOC. Pruebas con realimentación. Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra	Modelo Base
<b>Prueba 1</b>						
Base	58.37	82.85	32.21	79.33	59.33	
Día 1	76.99	83.89	91.95	81.01	57.33	Día 0
Día 3	55.86	88.28	69.13	19.55	86.00	Día 1
Día 5	66.95	79.92	53.69	86.03	57.33	Día 0
<b>Prueba 2</b>						
Base	64.44	88.49	65.77	39.66	92.67	
Día 1	73.85	92.68	78.52	60.89	84.67	Día 0
Día 2	51.26	79.08	47.97	63.89	39.33	Día 1
Día 4	68.62	89.75	75.84	56.98	75.33	Día 0

de datos EmoEpoc y EmoExt. Igualmente, cabe destacar que el colaborador es el mismo en ambas fases y posee experiencia previa utilizando Emotiv EPOC. Así mismo, el sujeto es consciente de la importancia de que el pensamiento entre sesiones sea consistente para que el sistema EEG funcione correctamente.

Para configurar la realimentación se realiza un procesamiento fuera de línea de los datos capturados en la sesión anterior y se parametrizan los modelos de la arquitectura S-dFasArt con los valores de  $\sigma$  y  $A_t$  que maximizan el rendimiento de los mismos. De este modo, el sistema “aprende” del usuario, por lo que se espera que la mejora en la precisión alcanzada en sesiones anteriores muestre un comportamiento beneficioso en la operación con realimentación actual. Atendiendo a los valores presentados, se alcanza un mejor resultado que el de la sesión de base sin realimentación para todos los experimentos que utilizan modelos generados a partir de la misma.

No obstante, el mejor resultado logrado siempre ocurre en la sesión siguiente a la de la captura inicial de los datos (Día 1). En la Prueba 1 se alcanza la mayor precisión mostrada utilizando Emotiv EPOC, con un 76.99% de rendimiento y en la Prueba 2 el segundo mejor valor con un 73.85% de acierto. Sin embargo esta mejora no se traslada a la siguiente sesión experimental, en la que en ambos casos se aprecia un descenso, quedando por debajo de la de base. Es más, parece que existe un nivel máximo de precisión para que los modelos obtenidos sean óptimos para su uso en siguiente iteración.

### 3.5. Conclusiones

Cabe destacar que la evaluación presentada en este capítulo ha sido realizada desde la perspectiva de un sistema BCI funcional completo, incluyendo las etapas de preprocesado y clasificación. Por tanto, no se ha analizado directamente la precisión en la detección de la señal capturada utilizando Emotiv EPOC, sino la precisión en la salida de un sistema

BCI construido utilizando datos capturados por varios dispositivos EEG distintos. Por este motivo, se ha seguido la guía propuesta para el BCI Competition III - dataset V.

### 3.5.1. Comparación datos BCI Competition III dataset V

Comparando los resultados mostrados en las Tablas 3.5 y 3.3 (Tabla 3.19), se pueden apreciar diferencias importantes entre las tasas de acierto obtenidas. De hecho, no sólo éstas han sido menores utilizando las posiciones de los sensores de Emotiv EPOC, sino que su distribución ha variado de un modo bastante significativo. Además, el rendimiento global se ha reducido alrededor de un 28 % para todos los sujetos. Por otra parte, no ha sido posible generalizar la distribución de los cambios ocasionando dicho descenso.

Tabla 3.19: Datos preprocesados BCI Competition III dataset V (BCIComp) vs BCI Competition III dataset V canales Emotiv (BCIEpoc). Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra
<b>Sujeto 1</b>					
BCIComp	87.67	92.47	78.91	92.31	90.56
BCIEpoc	63.40	83.19	93.57	19.72	73.94
Variación	<b>24.27</b>	<b>9.28</b>	<b>-14.66</b>	<b>72.59</b>	<b>16.62</b>
%	<b>27.68</b>	<b>10.04</b>	<b>-18.58</b>	<b>78.64</b>	<b>18.35</b>
<b>Sujeto 2</b>					
BCIComp	82.26	88.02	81.25	77.78	85.71
BCIEpoc	59.07	68.35	46.25	25.83	90.21
Variación	<b>23.19</b>	<b>19.67</b>	<b>35</b>	<b>51.95</b>	<b>-4.5</b>
%	<b>28.19</b>	<b>22.35</b>	<b>43.08</b>	<b>66.79</b>	<b>-5.25</b>
<b>Sujeto 3</b>					
BCIComp	58.72	75.23	73.97	24.00	80.00
BCIEpoc	42.23	59.45	32.72	26.58	67.95
Variación	<b>16.49</b>	<b>15.78</b>	<b>41.25</b>	<b>-2.58</b>	<b>12.05</b>
%	<b>28.08</b>	<b>20.98</b>	<b>55.77</b>	<b>-10.75</b>	<b>15.06</b>

Igualmente, se han podido apreciar comportamientos contradictorios entre los usuarios, tal y como muestra la Figura 3.11. Por ejemplo, ha aparecido una importante reducción en la capacidad de predecir Izquierda - *I* para los Sujetos 1 y 2 mientras que la variación no ha resultado tan significativa para el Sujeto 3. Igualmente, el acierto asociado a predecir Derecha - *D* ha mostrado una brusca disminución para los Sujetos 2 y 3 mientras que ha mejorado para el Sujeto 1. Lo que sí es un dato revelador ha sido la aparición de una variación mucho menor en la distinción efectiva entre Motor - *M* y Palabra - *P*. Motor - *M* ha permanecido en un rango entre el 10.04 % y el 22.35 % (12.31 puntos) mientras que *P* se ha mantenido entre el 5.25 % y el 18.35 % (13.1 puntos de diferencia).

Tabla 3.20: Datos preprocesados BCI Competition III dataset V (BCIComp) vs BCI Competition III dataset V canales Emotiv (BCIEpoc). Comparativa basada en la tasa media de acierto en %

	Tasa de acierto (%)				
	Global	Motor	Derecha	Izquierda	Palabra
BCIComp	76.22	85.24	78.04	64.7	85.42
BCIEpoc	54.9	70.33	57.51	24.04	77.37
Variación	<b>21.32</b>	<b>14.91</b>	<b>20.53</b>	<b>40.65</b>	<b>8.06</b>
%	<b>27.97</b>	<b>17.49</b>	<b>26.31</b>	<b>62.84</b>	<b>9.43</b>



Figura 3.11: Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos BCIComp vs BCIEpoc

Los resultados previos han quedado confirmados por la Tabla 3.20, que muestra el acierto medio de los sistemas para los usuarios de la muestra proporcionados por el BCI Competition III dataset V. Resulta evidente la existencia una fuerte reducción del rendimiento en la detección de la tarea *I* (62.84 %), mientras que para la tarea *D*, éste se ha mantenido en un 26.31 %, que está en línea con el decremento global del rendimiento del sistema (27.97 %). La predicción de la tarea *P* es la que ha alcanzado una predicción más robusta, con una pérdida de precisión limitada al 9.43 %.

### 3.5.2. Comparación datos EasyEpoc

Realizando un análisis análogo utilizando las bases de datos capturadas con el sistema híbrido Emotiv EPOC - EasyCap se han obtenido los resultados que aparecen en las Tablas 3.21 y 3.22. Cabe destacar antes de analizar éstos que existe una diferencia importante en relación con los del BCI Competition. Para el BCI Competition, la comparación se ha realizado sobre conjuntos de datos que parten de los mismos datos en *raw*. Es decir, que el Sujeto 1 que se compara es el mismo en la misma toma de datos.

Tabla 3.21: Datos preprocesados Emotiv EasyCap posiciones BCI (EasyBCI) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra
<b>Sujeto 1</b>					
EasyBCI	75.52	91.42	67.11	71.51	88.67
EasyEpoc	56.07	83.47	15.44	93.30	52.00
Variación	<b>19.45</b>	<b>7.95</b>	<b>51.67</b>	<b>-21.79</b>	<b>36.67</b>
%	<b>25.75</b>	<b>8.70</b>	<b>76.99</b>	<b>-30.47</b>	<b>41.36</b>
<b>Sujeto 2</b>					
EasyBCI	65.48	80.13	60.40	49.16	90
EasyEpoc	54.81	72.59	38.26	58.66	66.67
Variación	<b>10.67</b>	<b>7.54</b>	<b>22.14</b>	<b>-9.5</b>	<b>23.33</b>
%	<b>16.30</b>	<b>9.41</b>	<b>36.66</b>	<b>-19.32</b>	<b>25.92</b>
<b>Sujeto 3</b>					
EasyBCI	58.58	82.01	45.64	59.78	70.00
EasyEpoc	47.07	57.53	18.12	41.34	82.67
Variación	<b>11.51</b>	<b>24.48</b>	<b>27.52</b>	<b>18.44</b>	<b>-12.67</b>
%	<b>19.65</b>	<b>29.85</b>	<b>60.30</b>	<b>30.85</b>	<b>-18.10</b>

Tabla 3.22: Datos preprocesados BCI Competition III dataset V (BCIComp) vs BCI Competition III dataset V canales Emotiv (BCIEpoc). Comparativa basada en la tasa media de acierto en %

	<b>Tasa de acierto (%)</b>				
	Global	Motor	Derecha	Izquierda	Palabra
EasyBCI	66.53	84.52	57.72	60.15	82.89
EasyEpoc	52.65	71.20	23.94	64.43	67.11
Variación	<b>13.88</b>	<b>13.32</b>	<b>33.78</b>	<b>-4.28</b>	<b>15.78</b>
%	<b>20.86</b>	<b>15.76</b>	<b>58.22</b>	<b>-7.12</b>	<b>19.03</b>




Figura 3.12: Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos EasyBCI vs EasyEpoc

Por contra, las comparaciones incluidas en este estudio vinculan dos bases de datos diferentes, por lo que los datos comparados pertenecen a individuos distintos en diferentes instantes de tiempo. Una vez establecida esta salvedad, en dichas tablas se ha podido apreciar una tendencia similar a la presentada para los datos del BCI Competition III dataset V en cuanto al hecho de que han ocurrido descensos pronunciados en el rendimiento global del sistema. Sin embargo, si bien en el caso anterior la bajada media se ha encontrado alrededor del 28 % para todos los usuarios de forma homogénea, los descensos han variado entre el 16.30 % del Sujeto 2 y el 25.75 % del Sujeto 1.

Predecir Palabra - *P* ha sido la tarea acertada con mayor precisión para todos los colaboradores del experimento en las posiciones BCI Competition, y de dos de los tres sujetos del ejercicio en las posiciones Emotiv EPOC. Igualmente, se aprecia que para el Sujeto 3 del experimento EasyEpoc, la mejora prediciendo Palabra - *P* ha limitado la disminución general de su rendimiento.

Resulta destacable que las diferencias entre la capacidad de predecir las tareas motoras Izquierda - *I* y Derecha - *D* ha sido mucho más homogénea al situar los electrodos en las posiciones BCI Competition. La diferencias han sido de 4.4, 11.24 y 14.14 puntos para los Sujetos 1, 2 y 3 respectivamente, presentado una correspondencia inversa a la precisión global del sistema.

Por el contrario, se puede apreciar como estas diferencias han sido bastante abultadas para los datos EasyEpoc, situándose entre los 20 puntos del Sujeto 2 y los casi 78 del

Sujeto 1. Dado que en todos los casos es Izquierda -  $I$  la tarea que se ha predicho en mayor medida, se concluye que el sistema tiende a presentar esta predicción cuando se imaginan tareas motoras. Algo que han corroborado los incrementos del 30.47 % y 19.32 % en el acierto prediciendo  $I$  para los Sujetos 1 y 2 respectivamente.

Además, se ha podido establecer una relación directa entre la pérdida de capacidad de predecir Derecha -  $D$  correctamente y la bajada en la precisión del sistema. De una forma más concreta, el Sujeto 1, quien ha experimentado la mayor bajada en su tasa global de acierto (25.75 %), también ha presentado el mayor descenso prediciendo *Derecha*, en concreto de casi un 77 %. El Sujeto 3, segundo que más ha bajado (19.65 %) presenta un descenso del 60.30 %, lo que se ha repetido para el Sujeto 2 (16.30 %) con una disminución del estado en cuestión del 36.66 %.

En términos generales, tal y como muestra la Tabla 3.22, las diferencias en la ubicación de los sensores han originado un descenso medio del 20.86 % en el acierto general que ha conseguido el clasificador, con una marcada reducción en la capacidad de predecir la tarea Derecha -  $D$ .

Los datos presentados realzan la relevancia de la localización de los electrodos sobre el rendimiento del sistema. Como se puede observar, la mayoría de los cambios en la predicción se han dado entre las tareas motoras internamente ( $D$  vs.  $I$ ). Cuando se cambian las posiciones utilizadas para obtener datos en la corteza motora (sensores en verde en la Figura 2.30) a áreas más laterales no se pueden capturar de forma precisa los cambios en los ritmos  $\mu$  y  $\beta$  asociados a las tareas de imaginación de movimiento, lo que reduce la capacidad del sistema de detectar los fenómenos de ERD y ERS ([20]).

### 3.5.3. Comparación datos BCI Competition III Set V y Emotiv EasyCap - Posiciones BCI

Con el objetivo de establecer diferencias en la calidad de los equipos de captura de datos se han comparado los datos preprocesados del BCI Competition III Set V y del sistema híbrido Emotiv EPOC con la malla EasyCap. La primera aproximación que se presenta ha evaluado los datos obtenidos por electrodos situados en las las posiciones C3, Cz, C4, CP1, CP2, P3, Pz y P4 del sistema 10-20.

Como se puede apreciar en la Tabla 3.23 y en la Figura 3.13 los resultados conseguidos sobre los datos disponibles BCI Competition han sido mejores a aquéllos de la base de datos propia, con una diferencia entre el 0.24 y 20.40 %. Se ha establecido también una relación entre el rendimiento global del sistema alcanzado y la diferencia entre la capacidad de predecir correctamente cada tarea por cada par de usuarios comparados. Es decir, se ha podido observar que el Sujeto 1 de ambos juegos ha presentado las diferencias menores en el acierto de cada tarea Derecha -  $D$  (11.08 %), Izquierda -  $I$  (20.8 %) y Palabra -  $P$  (2.09 %), las cuales han ido aumentando hasta que para los usuarios comparados como Sujeto 3 han alcanzado los valores máximos: 38.30 % para  $D$ , 149.08 % para  $I$  y 12.05 % para  $P$ .

Se ha analizado entonces la variabilidad en la distinción efectiva entre Izquierda -  $I$  y Derecha -  $D$  para cada par de sujetos (Figura 3.14) y se ha encontrado que ésta ha seguido un orden creciente para los datos EasyBCI, si bien no se ha podido extraer



Tabla 3.23: Datos preprocesados BCI Competition III dataset V (BCIComp) vs Emotiv EasyCap posiciones BCI (EasyBCI). Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra
<b>Sujeto 1</b>					
BCIComp	87.67	92.47	78.91	92.31	90.56
EasyBCI	75.52	91.42	67.11	71.51	88.67
Variación	<b>12.15</b>	<b>1.05</b>	<b>11.8</b>	<b>20.8</b>	<b>1.89</b>
%	<b>13.86</b>	<b>1.14</b>	<b>14.95</b>	<b>22.53</b>	<b>2.09</b>
<b>Sujeto 2</b>					
BCIComp	82.26	88.02	81.25	77.78	85.71
EasyBCI	65.48	80.13	60.40	49.16	90.00
Variación	<b>16.78</b>	<b>7.89</b>	<b>20.85</b>	<b>28.62</b>	<b>-4.29</b>
%	<b>20.40</b>	<b>8.96</b>	<b>25.66</b>	<b>36.80</b>	<b>-5.01</b>
<b>Sujeto 3</b>					
BCIComp	58.72	75.23	73.97	24.00	80.00
EasyBCI	58.58	82.01	45.64	59.78	70.00
Variación	<b>0.14</b>	<b>-6.78</b>	<b>28.33</b>	<b>-35.78</b>	<b>10.00</b>
%	<b>0.24</b>	<b>-9.01</b>	<b>38.30</b>	<b>-149.08</b>	<b>12.50</b>

Tabla 3.24: Datos preprocesados BCI Competition III dataset V (BCIComp) vs Emotiv EasyCap posiciones BCI (EasyBCI). Comparativa basada en la tasa media de acierto en %

	<b>Tasa de acierto (%)</b>				
	Global	Motor	Derecha	Izquierda	Palabra
BCIComp	76.22	85.24	78.04	64.7	85.42
EasyBCI	66.53	84.52	57.72	60.15	82.89
Variación	<b>9.69</b>	<b>0.72</b>	<b>20.33</b>	<b>4.55</b>	<b>2.53</b>
%	<b>12.71</b>	<b>0.84</b>	<b>26.05</b>	<b>7.03</b>	<b>2.97</b>

tendencia alguna para los datos BCIComp.

No obstante, el dato más relevante se ha encontrado en la variación inter usuario para cada base de datos teniendo en cuenta que todos han sido noveles. Para los datos EasyBCI, la tasa de acierto se ha situado entre el 75.52 % para el Sujeto 1 y el 58.58 % para el Sujeto 3, lo que ha supuesto una variación de 16.94 puntos. Sin embargo, para los datos preprocesados BCIComp, la diferencia se ha elevado a 28.95 puntos, lo que es la mayor variación entre el Sujeto 1 y el 3 encontrada en todas las bases de datos estudiadas. Es destacable que en términos medios que estas diferencias se han amortiguado debido a que no todos los usuarios han acertado con mayor precisión la misma tarea motora, si bien ha quedado claro que la menor variación se encuentra en los datos propios.



Figura 3.13: Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos BCIComp vs EasyBCI




Figura 3.14: Variación del el acierto de clasificación para las tareas Izquierda - *I* y Derecha - *D* en valor absoluto. Datos BCIComp vs EasyBCI

Finalmente, se ha podido comprobar que el porcentaje de variación de la precisión general del sistema se ha reducido hasta el 12.71 %, con valores muy bajos para Motor - *M* y Palabra - *P* y limitados para Izquierda - *I*. Por tanto, se concluye que los datos EasyBCI han adolecido de una menor tasa de acierto fundamentalmente porque la señal capturada no ha permitido la distinción de la tarea Derecha - *D* de una forma más efectiva.

### 3.5.4. Comparación datos BCI Competition III Set V y Emotiv EasyCap - Posiciones Emotiv

En consonancia con el apartado anterior se presenta en éste una comparación entre los datos *raw* del BCI Competition III Dataset V y los capturados con el sistema híbrido Emotiv EPOC con la malla EasyCap para las ubicaciones de los sensores AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4.

Tabla 3.25: Datos preprocesados BCI Competition III dataset V en las posiciones Emotiv (BCIEpoc) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra
<b>Sujeto 1</b>					
BCIEpoc	63.40	83.19	93.57	19.72	73.94
EasyEpoc	56.07	83.47	15.44	93.30	52.00
Variación	<b>7.33</b>	<b>-0.28</b>	<b>78.13</b>	<b>-73.58</b>	<b>21.94</b>
%	<b>11.56</b>	<b>-0.34</b>	<b>83.50</b>	<b>-373.12</b>	<b>29.67</b>
<b>Sujeto 2</b>					
BCIEpoc	59.07	68.35	46.25	25.83	90.21
EasyEpoc	54.81	72.59	38.26	58.66	66.67
Variación	<b>4.26</b>	<b>-4.24</b>	<b>7.99</b>	<b>-32.83</b>	<b>23.54</b>
%	<b>7.21</b>	<b>-6.20</b>	<b>17.28</b>	<b>-127.10</b>	<b>26.09</b>
<b>Sujeto 3</b>					
BCIEpoc	42.23	59.45	32.72	26.58	67.95
EasyEpoc	47.07	57.53	18.12	41.34	82.67
Variación	<b>-4.84</b>	<b>1.92</b>	<b>14.60</b>	<b>-14.76</b>	<b>-14.72</b>
%	<b>-11.46</b>	<b>3.23</b>	<b>44.62</b>	<b>-55.53</b>	<b>-21.66</b>

Tabla 3.26: Datos preprocesados BCI Competition III dataset V (BCIComp) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa media de acierto en %

	<b>Tasa de acierto (%)</b>				
	Global	Motor	Derecha	Izquierda	Palabra
BCIEpoc	54.90	70.33	57.51	24.04	77.37
EasyEpoc	52.65	71.20	23.94	64.43	67.11
Variación	<b>2.25</b>	<b>-0.87</b>	<b>33.57</b>	<b>-40.39</b>	<b>10.25</b>
%	<b>4.10</b>	<b>-1.23</b>	<b>58.37</b>	<b>-167.99</b>	<b>-20.98</b>



Figura 3.15: Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos BCIEpoc vs EasyEpoc

Es destacable la disminución de la variabilidad inter usuario para cada base de datos, quedando para datos BCIEpoc en 21.17 puntos, y reduciéndose a nueve puntos para los datos EasyEpoc. Igualmente, y por primera vez para todos los juegos de datos, el usuario presentando la tercera mejor tasa de acierto de una base de datos propia ha superado a el Sujeto 3 del BCI Competition, en este caso en 4.84 puntos. También ha resultado evidente la poca variabilidad entre los aciertos globales para los tres pares de usuarios, que se han situado entre los 4.26 puntos para Sujeto 2 y los 7.33 para el 1. La misma tendencia se ha encontrado al examinar la capacidad de distinción efectiva de la tarea Motor -  $M$ , generando diferencias de entre 0.28 y 4.24 puntos.

Del mismo modo, de la Tabla 3.25 se extrae cómo, para todos los casos, los datos BCIEpoc han permitido predecir Derecha -  $D$  de un modo más preciso que Izquierda -  $I$ , incluso con diferencias extremadamente amplias, como la que se ha mostrado para el Sujeto 1. Mientras tanto, los datos EasyEpoc han presentado un comportamiento análogo, pero en este caso prediciendo Izquierda -  $I$  en mayor medida para todos los sujetos.

El análisis de las tareas predecir Izquierda -  $I$  y Derecha  $D$  ha mostrado un alto grado de variabilidad entre las mismas para el Sujeto 1, con un valor algo menos acentuado para el 2, pero que se ha mantenido estable para el Sujeto 3 EasyEpoc. No obstante, como se aprecia en la Figura 3.16, los pares de Sujetos 1 y 2 han variado dentro del mismo rango pero en sentido opuesto, es decir mientras los Sujetos 1 y 2 BCIEpoc han predicho  $D$  mayoritariamente, los Sujetos 1 y 2 EasyEpoc han hecho lo propio con  $I$ . Los Sujetos 3




Figura 3.16: Variación entre el acierto de clasificación para las tareas Izquierda - *I* y Derecha - *D* en valor absoluto. Datos BCIEpoc vs EasyEpoc

han presentado un comportamiento distinto y, en este caso la diferencia en el rendimiento entre *I* y *D* se ha reducido para el conjunto de datos BCIEpoc mientras que ha ascendido a 23.22 puntos para el EasyEpoc. Por último, cabe destacar el decremento de 10.25 puntos en el acierto de Palabra - *P* en el Sujeto 3 BCIEpoc, que ha sido determinante para que se alcanzase una mayor tasa de acierto en los datos capturados EasyEpoc.

Finalmente, se concluye que la ubicación de los sensores en las zonas más laterales del cráneo conlleva una polarización del acierto de clasificación de las tareas motoras, de forma que cualquiera de los sistemas EEG estudiados acertará predominantemente Izquierda - *I* o Derecha - *D*.

### 3.5.5. Comparación de datos disponibles para posiciones Emotiv EPOC

En esta sección se comparan todas las bases de datos para las que se han situado electrodos en las ubicaciones de Emotiv EPOC. Por tanto, se han utilizado los datos en las posiciones AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 del conjunto de datos *raw* del BCI Competition III Dataset V (BCIEpoc) y los del sistema híbrido Emotiv EPOC EasyCap (EasyEpoc), junto con la primera base de datos de tres usuarios capturada con Emotiv EPOC. En primer lugar, se ha procedido a analizar bilateralmente cada uno de los grupos de datos anteriores en relación con la base de datos de tres usuarios de Emotiv EPOC.

Comenzando con los datos de la Tabla 3.27, es relevante que la precisión media obtenida por el clasificador S-dFasArt para los datos capturados con Emotiv EPOC ha superado en más de un 12 % la calculada para el conjuntos de datos el BCI Competition III dataset V seleccionando únicamente los canales Emotiv (Tabla 3.28). De un modo más detallado, se ha obtenido una precisión global en torno a cinco puntos mejor para los dos mejores pares de usuarios de cada conjunto de datos (Sujetos 1 y 2) y hasta un 23 % más alta para los datos Emotiv EPOC del Sujeto 3.

Resulta interesante analizar en detalle la tarea Motor - *M* dado que se ha podido observar cómo la precisión del sistema ha sido muy similar para los datos obtenidos con Emotiv

Tabla 3.27: BCI Competition III dataset V canales Emotiv (BCIEpoc) vs Datos capturados con Emotiv EPOC (EmoEpoc). Comparativa basada en la tasa de acierto en % [160]

	Global	Motor	Derecha	Izquierda	Palabra
<b>Sujeto 1</b>					
EmoEpoc -	69.04	82.22	41.61	72.63	92.00
BCIEpoc -	63.40	83.19	93.57	19.72	73.94
Variación	<b>5.64</b>	<b>-0.97</b>	<b>-51.96</b>	<b>52.91</b>	<b>18.06</b>
%	<b>8.17</b>	<b>-1.18</b>	<b>-124.87</b>	<b>72.85</b>	<b>19.63</b>
<b>Sujeto 2</b>					
EmoEpoc	63.50	82.51	49.43	93.79	50.00
BCIEpoc	59.07	68.35	46.25	25.83	90.21
Variación	<b>4.43</b>	<b>14.16</b>	<b>3.18</b>	<b>67.96</b>	<b>-40.21</b>
%	<b>6.98</b>	<b>17.16</b>	<b>6.43</b>	<b>72.46</b>	<b>-80.42</b>
<b>Sujeto 3</b>					
EmoEpoc	55.29	80.35	47.40	53.10	66.90
BCIEpoc	42.23	59.45	32.72	26.58	67.95
Variación	<b>13.06</b>	<b>20.9</b>	<b>14.68</b>	<b>26.52</b>	<b>-1.05</b>
%	<b>23.62</b>	<b>26.01</b>	<b>30.97</b>	<b>49.94</b>	<b>1.57</b>

Tabla 3.28: BCI Competition III dataset V canales Emotiv (BCIEpoc) vs Datos capturados con Emotiv EPOC (EmoEpoc). Comparativa basada en la tasa media de acierto en % [160]

	<b>Tasa de Acierto (%)</b>				
	Global	Motor	Derecha	Izquierda	Palabra
EmoEpoc	62.61	81.69	46.15	73.17	69.63
BCIEpoc	54.90	70.33	57.51	24.04	77.37
Variación	<b>7.71</b>	<b>11.36</b>	<b>-11.37</b>	<b>49.13</b>	<b>-7.73</b>
%	<b>12.31</b>	<b>13.91</b>	<b>-24.63</b>	<b>67.14</b>	<b>-11.11</b>

EPOC, mientras que ha diferido significativamente en los datos BCIEpoc (encontrándose entre el 59.45 % y el 83.19 %). Comparando los resultados con un mayor nivel de detalle, se ha podido encontrar una precisión mayor en Emotiv EPOC prediciendo Izquierda - *I* y una mayor en los datos BCIEpoc prediciendo Derecha - *D*.

Como revela la Tabla 3.28, el rendimiento medio ha sido hasta un 12.31 % mayor con Emotiv EPOC. Del mismo modo, se aprecia una distribución más uniforme de la tasa de acierto entre las predicciones, mostrándose una varianza de 27.03 puntos entre la tarea predicha con una mayor precisión (Izquierda - *I*) y la de menor (Derecha - *D*), comparada con 53.32 puntos para los datos BCIEpoc (Palabra - *W* menos Izquierda - *I*) ([160]).

La evaluación de los resultados alcanzados para la base de datos Emotiv EPOC de tres

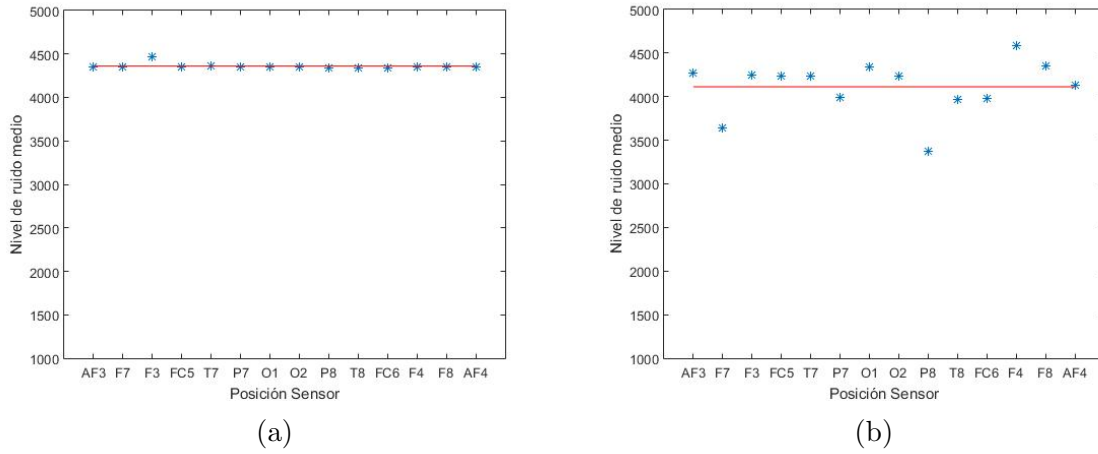


Figura 3.17: Valor medio de la señal medida por cada sensor (a) Emotiv EPOC. Valor medio:  $4,360.2e+003$ . (b) Emotiv EasyCap, Valor medio:  $4,113.2e+003$




Figura 3.18: Varianza de la señal medida por cada sensor (a) Emotiv EPOC. Valor medio:  $1,520.6e+003$ . (b) Emotiv EasyCap, Valor medio:  $2,583.7e+003$

usuarios y los datos Emotiv EasyCap es de especial relevancia dado que, aunque se trata de sesiones diferentes y usuarios distintos, la tecnología de procesamiento de la información ha sido la misma, por lo que se esperan resultados consistentes entre ambas. Cabe recordar en este punto que para el sistema híbrido Emotiv EasyCap se ha sustituido el armazón plástico de Emotiv EPOC por un cableado y sensores diferentes, que han permitido su colocación en la malla EasyCap ([106, 121]).

Para determinar diferencias entre ambos derivadas de la calidad de los electrodos y el cableado, se ha analizado el ruido de la señal detectado cuando los sensores de ambos sistemas EEG no se encuentran en contacto con el cuero cabelludo. Para ello se ha realizado una captura de datos de cuatro sesiones en la que tanto Emotiv EPOC como el sistema

Tabla 3.29: Datos Emotiv EPOC (EmoEpoc) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra
<b>Sujeto 1</b>					
EmoEpoc	69.04	82.22	41.61	72.63	92.00
EasyEpoc	56.07	83.47	15.44	93.30	52.00
Variación	<b>12.97</b>	<b>-1.25</b>	<b>26.17</b>	<b>-20.67</b>	<b>40.00</b>
%	<b>18.79</b>	<b>-1.52</b>	<b>62.89</b>	<b>-28.46</b>	<b>43.48</b>
<b>Sujeto 2</b>					
EmoEpoc	63.50	82.51	49.43	93.79	50.00
EasyEpoc	54.81	72.59	38.26	58.66	66.67
Variación	<b>8.69</b>	<b>9.92</b>	<b>11.17</b>	<b>35.13</b>	<b>-16.67</b>
%	<b>13.69</b>	<b>12.02</b>	<b>22.60</b>	<b>37.46</b>	<b>-33.34</b>
<b>Sujeto 3</b>					
EmoEpoc	55.29	80.35	47.40	53.10	66.90
EasyEpoc	47.07	57.53	18.12	41.34	82.67
Variación	<b>8.22</b>	<b>22.82</b>	<b>29.28</b>	<b>11.76</b>	<b>-15.77</b>
%	<b>14.87</b>	<b>28.40</b>	<b>61.77</b>	<b>22.15</b>	<b>-23.57</b>

Tabla 3.30: Datos Emotiv EPOC (EmoEpoc) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa media de acierto en %

	<b>Tasa de acierto (%)</b>				
	Global	Motor	Derecha	Izquierda	Palabra
EmoEpoc	62.61	81.69	46.15	73.17	69.63
EasyEpoc	52.65	71.20	23.94	64.43	67.11
Variación	<b>9.96</b>	<b>10.50</b>	<b>22.21</b>	<b>8.74</b>	<b>2.52</b>
%	<b>15.91</b>	<b>12.85</b>	<b>48.12</b>	<b>11.94</b>	<b>3.62</b>

híbrido han permanecido suspendidos. A partir de ella, se ha calculado el valor medio de la señal para cada uno de los 14 sensores, representado en la Figura 3.17. Se puede observar que los valores medios en ambos casos han sido muy parecidos, por lo que se ha asumido que el nivel medio de ruido medido no depende del tipo de sensor utilizado. De igual forma, el cálculo de la varianza de señal ha mostrado valores homogéneos entre los sensores de ambos equipos, tal y como se ha recogido en la Figura 3.18.

Atendiendo a los valores disponibles en las Tablas 3.29 y 3.30, es destacable que las tasas de acierto alcanzadas con Emotiv EPOC han sido mayores en todos los casos a las conseguidas utilizando EasyCap, lo que es consistente con los datos anteriores BCIEpoc.

Además, se ha contrastado que la diferencia entre estados motores se minimiza con



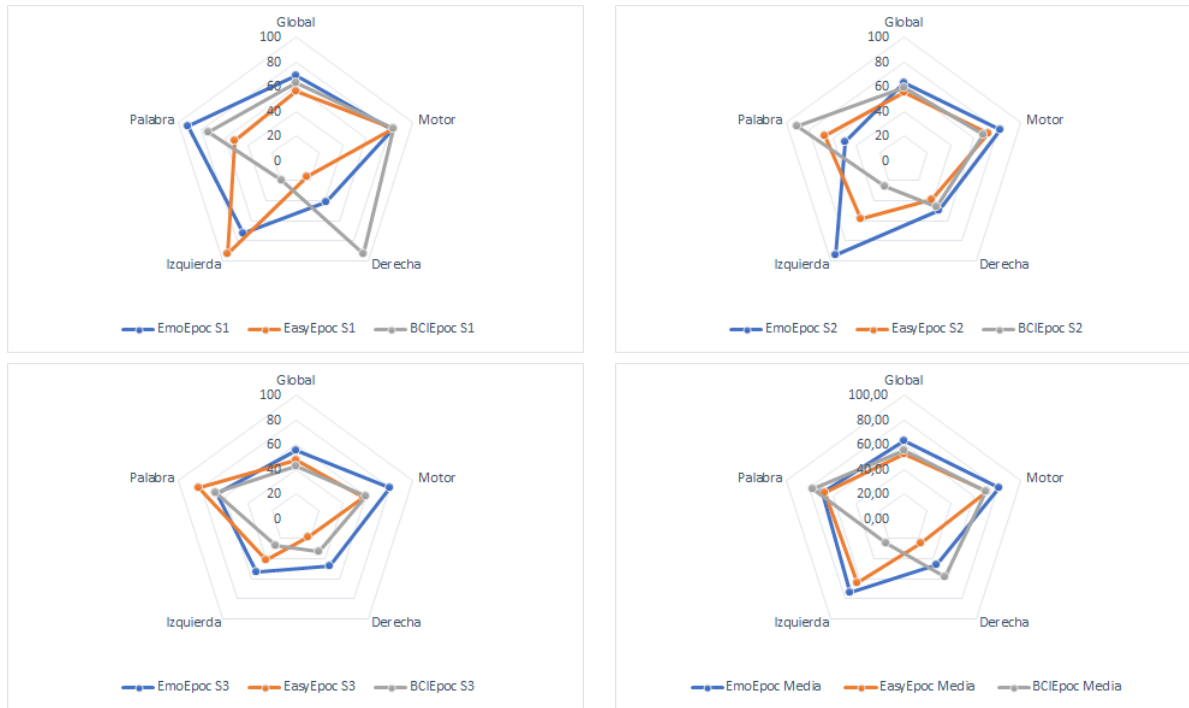


Figura 3.19: Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos EmoEpoc, BCIEpoc y EasyEpoc




Figura 3.20: Variación en el acierto de clasificación para las tareas Izquierda - *I* y Derecha - *D* en valor absoluto. Diferentes conjuntos de datos en posiciones Emotiv

Emotiv EPOC (Figura 3.20), por lo que los datos capturados con este dispositivo han hecho posible una detección más homogénea entre las tareas motoras. No obstante, esta diferencia también ha estado determinada por la posición de los sensores. Tomando como ejemplo datos capturados con Emotiv EPOC EasyCap se aprecia que la variación de acierto entre los estados Izquierda - *I* y Derecha - *D* ha crecido desde los 27.03 para la base de

datos EasyBCI hasta los 40.49 de EasyEpoc.

Finalmente, y atendiendo a la comparación entre los tres conjuntos de datos mostrada en la Figura 3.19, se ha podido observar que tanto en términos medios como cuando se han comparado los valores de los Sujetos 1 y 3 de los diferentes juegos de datos, aquéllos capturados con Emotiv EPOC han mostrado una mayor homogeneidad. Así mismo, los valores presentando una mayor variabilidad han sido los asociados a la predicción de  $I$  y  $D$ , con los conjuntos de datos EmoEpoc y Emotiv EasyCap con una tendencia clara a predecir  $I$  sobre  $D$  y los BCI Competition mostrando el comportamiento inverso. Palabra -  $P$  también ha mostrado una amplia variabilidad entre los diferentes Sujetos, pero los resultados no han sido consistentes para ningún conjunto de datos, homogeneizándose en media.

### 3.5.6. Generalización de los resultados Emotiv EPOC base de datos extendida

El presente apartado compara los valores encontrados al analizar la base de datos de tres usuarios de Emotiv EPOC con la versión ampliada de la misma. Como se puede apreciar los datos EmoEpoc han proporcionado una mayor precisión media en todos los casos. Esto se debe en primera instancia al acierto conseguido para los usuarios incluidos. De hecho, los Sujetos 1 y 2 de la base de datos de Emotiv serían el primero y tercero respectivamente de la base de datos ampliada atendiendo a la tasa de acierto conseguida.

Tabla 3.31: Datos Emotiv EPOC (EmoEpoc) vs Datos Emotiv EPOC Ext (EmoExt). Comparativa basada en la tasa media de acierto en %

	Tasa de acierto (%)				
	Global	Motor	Derecha	Izquierda	Palabra
EmoEpoc	62.61	81.69	46.15	73.17	69.63
EmoExt	56.99	75.82	32.42	67.85	68.59
Variación	<b>5.62</b>	<b>5.87</b>	<b>13.73</b>	<b>5.32</b>	<b>1.04</b>
%	<b>8.97</b>	<b>7.19</b>	<b>29.75</b>	<b>7.27</b>	<b>1.49</b>

Del mismo modo, al examinar los valores medios se han mantenido las tendencias establecidas para la base de datos EmoEpoc. Es decir, independientemente de los usuarios incluidos, pensar en mover la mano Izquierda -  $I$  se ha acertado en una proporción similar o mayor que Palabra -  $P$  mientras que predecir Derecha -  $D$ , que ha mostrado el mayor descenso, se ha acertado únicamente entre el 50 y el 60 % de lo que se hecho con  $I$ .

Es decir, los cambios derivados de la pérdida de capacidad de predecir Derecha -  $D$  han tenido un impacto en la capacidad del sistema de predecir Motor -  $M$ . Sin embargo, predecir Palabra -  $P$  se ha mantenido bastante estable entre las bases de datos, luego se puede concluir que la detección de este pensamiento es ciertamente robusta.

### 3.5.7. Análisis General

El procedimiento de colocación de Emotiv EPOC ha sido rápido y sencillo para aquellos usuarios de pelo corto o fino. Sin embargo, se ha tornado laborioso para colaboradores de pelo largo y hasta cierto punto grueso. En estos casos, ha sido necesario apartar el pelo de alrededor de cada uno de los sensores. Igualmente, es revelador que todas las sesiones capturadas en personas con pelo de estas características han sido descartadas por sus bajos niveles de precisión, lo que hace dudar de la calidad de la señal capturada, tal y como se discute en [162]. También es reseñable que, si bien el uso durante de Emotiv EPOC sólo ha sido considerado molesto por dos usuarios, hasta seis de ellos han sugerido mejoras en la ergonomía del mismo [163]. Además, los sensores han dejado una marca sobre la piel visible después de alrededor de media hora de uso, dependiendo del tamaño de la cabeza.




Figura 3.21: Comparativa del acierto medio de clasificación para las diferentes tareas. Datos EmoEpoc, BCIEpoc, EasyEpoc y EasyBCI

La Figura 3.21 muestra los aciertos de todas las bases de datos que contienen datos capturados en las posiciones Emotiv EPOC, junto a la base de datos EasyBCI. Cabe destacar que el acierto mostrado es en porcentaje y que no se han incluido los valores conseguidos en los datos de BCIEpoc para facilitar la legibilidad del gráfico.

En primer lugar, se puede apreciar que los datos capturados con Emotiv EPOC han proporcionado el mejor acierto de clasificación medio en las posiciones del sistema 10-20 que ocupan. De un modo más detallado, se puede observar que éstos han sido mejores en todas las tareas a los datos EasyEpoc. Sin embargo, han ofrecido peores resultados para predecir Derecha - *D* y Palabra - *P* que los de la base de datos BCIEpoc. Igualmente, la capacidad de acierto de la tarea motora Izquierda - *I* ha sido mucho mayor que para el resto de los casos, si bien predecir Derecha - *D* ha mostrado unos resultados más modestos. Este resultado es consistente con su matriz de confusión (Tabla 3.6), donde se puede observar que *I* ha sido el valor más propuesto por el clasificador para todos los casos.

Este comportamiento ha quedado contrastado por los resultados obtenidos en la base de datos de 12 usuarios, donde se ha identificado *I* como la tarea motora más acertada por 11 de los 12 usuarios, con un amplio margen de diferencia para nueve de ellos. Del mismo modo, al estudiar las confusiones a nivel global se ha observado (Figuras 3.7 y 3.8)




Figura 3.22: Comparativa del acierto medio de clasificación para las diferentes tareas. Datos EmoEpoc, BCIEpoc y EasyEpoc

cómo predecir  $D$  y  $P$  erróneamente se relaciona con la presentación de la predicción  $I$ . Por tanto, se puede concluir que la predicción presentada con mayor frecuencia es Izquierda -  $I$  cuando se utiliza un Emotiv EPOC. Del mismo modo, y teniendo en cuenta tanto las matrices de confusión de la base de datos de 12 usuarios como los datos mostrados en la Figura 3.21, queda claro que el segundo valor que el clasificador ha presentado de una forma más frecuente ha sido Palabra -  $P$  (Tabla 3.6).

Al comparar las bases de datos obtenidas con EasyCap ha sido evidente el efecto de la distribución de los sensores sobre la homogeneidad del sistema precidiciendo tareas motoras. Tomando como ejemplo predecir Derecha -  $D$ , se aprecia que una distribución de los sensores cubriendo la corteza motora ofrece resultados más homogéneos entre las dos tareas motoras, al mismo tiempo que afianza los resultados de la tarea Palabra -  $P$ .

La Figura 3.22 recoge la comparación entre los valores medios de acierto con Emotiv EPOC y aquéllos calculados en los escenarios en los que se han tomado valores en las posiciones C3, Cz, C4, CP1, CP2, P3, Pz y P4. En ella se puede observar un aumento en la precisión general y diferencias importantes en la capacidad de predecir Derecha -  $D$ . Del mismo modo, la predicción de Palabra -  $P$  se ha elevado considerablemente. En definitiva, se corroboran las premisas encontradas en la literatura y aquéllas realizadas al analizar información capturada en otras bases de datos.

En resumen, los resultados obtenidos son consistentes con los presentados en la literatura. Se ha encontrado que las posiciones en los electrodos presentan una relación directa con la precisión del sistema. Desafortunadamente, el Emotiv EPOC carece de sensores sobre el área de la corteza motora (posiciones C3 y C4), que es donde las intenciones motoras se discriminan con una mayor precisión, lo que limita su precisión en la detección de tareas motoras.

Sin embargo, se ha encontrado que Emotiv EPOC provee un rendimiento en la predicción de tareas para el experimento considerado mayor que la que presenta cualquier alternativa para las mismas ubicaciones de los sensores. Por tanto, desde el punto de vista de construcción de un sistema BCI basado en EEG, parece que la tecnología de los com-

ponentes de los sensores puede pasar a un segundo plano cuando se utiliza un sistema de procesamiento óptimo.

Finalmente, la realimentación ha mostrado una influencia positiva en la precisión lograda operando el sistema BCI, permitiendo al usuario involucrado en esta prueba alcanzar tasas de acierto por encima del 70 % utilizando Emotiv EPOC. No obstante, se han encontrado resultados contradictorios en tanto las sesiones inmediatamente posteriores a éstas han presentado resultados más bajos que los iniciales sin realimentación. Sin embargo, al volver a utilizar los parámetros extraídos de los modelos de base, las tasas de acierto clasificación han vuelto a ascender notablemente. Por tanto, sería necesario determinar si la mejor aproximación para el aprendizaje consiste en mantener la configuración inicial durante un número de sesiones o si, por el contrario, existen modelos que optimicen este proceso.



## Capítulo 4

# Selección de Características

En los últimos años ha surgido un creciente interés en simplificar los dispositivos EEG aplicados a problemas BCI específicos con el objetivo de facilitar su operación y minimizar su coste. Así mismo, se requiere que la utilización de este tipo de sistemas se pueda realizar en cualquier momento o lugar.

Dado que multitud de algoritmos de clasificación óptimos en la detección de patrones cerebrales presentan fuertes requisitos computacionales, su integración en sistemas de tiempo real se torna dificultosa. Fundamentalmente, el tiempo máximo disponible para realizar los cálculos puede requerir de una capacidad de procesamiento que drene rápidamente las baterías de los dispositivos móviles integrados, limitando así su uso a entornos donde existe una conexión permanente a la red eléctrica.

Si se entiende además que las personas impedidas son el público objetivo más evidente de este tipo de equipos, no resulta admisible se continúe limitando su capacidad de movimiento. Por tanto, una reducción en la complejidad de los sistemas BCI se presenta como un paso de capital importancia cara a su diseño e implementación. Como consecuencia, existen multitud de trabajos destinados a simplificar los requisitos de este tipo de dispositivos, si bien siempre tomando la reducción en el número de sensores como finalidad de su investigación.

En esta tesis doctoral se afronta el novedoso reto de minimizar el conjunto de datos requerido en los sistemas BCI, analizando para ello la contribución de cada característica frecuencial de forma individual a la precisión de los mismos. Así se puede no sólo contribuir a una simplificación de los equipos EEG en la fase de captura de datos, sino que resulta posible reducir la cantidad de información a procesar, disminuyendo así los requisitos computacionales en la fase de clasificación. Se definen dos nuevas aproximaciones: una basada en las propiedades estadísticas de los datos y otra utilizando la relación entre las características difusas que se generan para un modelo S-dFasArt.

Los resultados mostrados en este capítulo han sido obtenidos a partir las bases de datos presentadas en la sección 3.1.1.

## 4.1. Metodología

Se desarrolla un nuevo procedimiento para reducir el tamaño del conjunto de componentes frecuenciales de la entrada, el cual es inicialmente el resultado de multiplicar el número de sensores utilizados en el experimento por el número de frecuencias que se consideran en el cálculo de la PSD.

Con el objetivo de optimizar el resultado se integran el mecanismo de selección de características y el clasificador S-dFasArt en una misma arquitectura. De este modo se establece una sinergia entre el sistema de clasificación, que muestra un rendimiento superior a otras aproximaciones aplicadas a este experimento, y el mecanismo de selección de características, que reduce significativamente el tamaño del vector de entrada. La metodología aplicada se puede definir del siguiente modo [164]:

1. Búsqueda del carácter discriminante cada componente del vector. Se determina la capacidad segregatoria de cada característica en cada uno de los seis módulos S-dFasArt de la arquitectura (Figura 2.35) utilizando dos métodos diferentes:
  - a) Método estadístico. Se basa en resultados estadísticos utilizados normalmente en problemas de reconocimiento de patrones. Este criterio únicamente depende de los datos.
  - b) Criterio difuso. Parte de las características de la arquitectura S-dFasArt como un sistema lógico difuso, que incluye un conjunto de reglas que unen la unidades difusas. Por consiguiente, este criterio se ve afectado tanto por los datos de entrada como por el conjunto de reglas que define el modelo neurodifuso.
2. Puntuación, ordenación y selección. Para este estudio, se propone un método de preselección basado en el carácter discriminante de cada componente calculado en el punto anterior. Para ello se toman las diez características más relevantes para cada sesión de entrenamiento y se puntúan entre 1 y 10, identificando 10 el valor mayor de singularización. A partir de los datos anteriores, éstas se ordenan de forma descendiente de acuerdo a la puntuación obtenida y se suman todas las puntuaciones para cada una. Así se crea un ranking, de forma que se puede realizar una primera selección de las componentes frecuenciales a formar parte del vector reducido.
3. Selección de características. En esta etapa se escogen aquellas características candidatas que alcanzan la mayor precisión utilizando el clasificador S-dFasArt. Para obtener el subconjunto más representativo, se proponen dos métodos:
  - a) Selección por Orden. Ordenando las componentes frecuenciales preseleccionadas de acuerdo a una puntuación dada SCORE  $(x_1, \dots, x_D)$ , sólo se consideran  $D$  posibles vectores de características  $\{(x_1), (x_1, x_2), (x_1, x_2, x_3) \dots (x_1 \dots x_D)\}$ . La precisión de cada opción individual se calcula aplicando una validación cruzada de  $k$  iteraciones con las tres sesiones de aprendizaje disponibles utilizando el clasificador S-dFasArt. Finalmente, se escogen las características que ofrecen una mayor precisión.



- b) Método Grupal de Manejo de Datos (GMDH del inglés Group Method of Data Handling) [165]. Este método de selección evalúa las características a añadir al subconjunto de acuerdo a un criterio de regularidad (RC del inglés Regularity Criterion).

De las cuatro sesiones disponibles por usuario en todas las bases de datos, se utilizan las tres primeras para realizar el entrenamiento y la última como sesión de validación. Los conjuntos de entrenamiento permiten obtener un número mínimo de características para cada combinación de elementos de la metodología presentada, mientras que la última sesión se usa para comprobar la precisión del modelo propuesto.

#### 4.1.1. Carácter discriminante de las características

Se utilizan dos metodologías basadas en los conjuntos de entrenamiento con el objetivo de evaluar la naturaleza discriminante de cada una de las componentes del vector de características: la primera de ellas se apoya en la aplicación de métodos estadísticos clásicos, mientras que la segunda se basa en la interpretación en lógica difusa del clasificador creado a partir del conjunto de entrenamiento.

##### 1. Método estadístico de selección de características

El problema a resolver se puede definir como un problema de clasificación de  $M$  dimensiones en  $C$  clases. De acuerdo con esta premisa, se utiliza un conjunto de vectores correctamente clasificado, denominado conjunto de entrenamiento o aprendizaje, para estudiar la contribución relativa de cada una de las  $M$  características del vector de muestras a la separabilidad de las clases. Como consecuencia, se calculan las propiedades de los resultados estadísticos del conjunto de entrenamiento.

Se denomina  $\gamma_{ij}$  a la varianza para la característica  $j$ -ésima en la  $i$ -ésima clase, siendo  $P_i$  la probabilidad a priori de la  $i$ -ésima clase y  $\lambda_j$  el valor total de la varianza para la muestra  $j$ -ésima. La varianza normalizada se define como:

$$\tilde{\gamma}_{ij} = P_i \frac{\gamma_{ij}}{\lambda_j} \quad (4.1)$$

Cuando se establece el criterio para determinar la contribución a la capacidad discriminatoria de cada una de las características, la entropía estadística se estima como:

$$J(x_j) = \sum_{i=1}^C \tilde{\gamma}_{ij} \log(\tilde{\gamma}_{ij}) \quad (4.2)$$

Que alternativamente permite mostrar la información discriminante de cada componente en la forma:

$$J(x_j) = \prod_{i=1}^C \tilde{\gamma}_{ij} \quad (4.3)$$

Esta expresión presenta un valor máximo igual a  $(1/C)^C$  cuando todos los valores de  $\tilde{\gamma}_{ij}$  son iguales para una determinada característica  $i$ . En este escenario, se puede concluir que la característica  $i$  no añade información discriminante y se puede descartar.

## 2. Criterio difuso de selección de características

En este caso se considera la arquitectura S-dFasArt (Figura 2.35) como punto de partida. Ésta se construye utilizando las tres sesiones de entrenamiento del modo detallado en la Figura 4.1, donde se puede apreciar paso a paso como se crean cada uno de los seis modelos.

Para realizar la selección de características, el módulo de votación se reemplaza por un modelo S-dFasArt intermedio, donde cada clase se puede interpretar como una regla cuya función de transferencia queda determinada por los pesos asociados a los conjuntos difusos. Así, los pesos se calculan como la media de los pesos que predicen dicha categoría mientras que la regla asociada a la clase  $i$ -ésima de cada característica  $j$  queda representada por un conjunto  $A_j^i$  como:

SI  $x_1$  ES  $A_1^i$  Y  $x_2$  ES  $A_2^i$  Y ... Y  $x_{96}$  ES  $A_{96}^i$

También se asume que el carácter discriminante de cada componente está unido a la relación entre sus conjuntos difusos asociados entre dos clases. Si estos conjuntos difusos son muy similares, la característica no es muy discriminante. Si, por el contrario, los conjuntos difusos son claramente diferentes, el carácter discriminante de cada componente aumenta. Dicho valor se calcula comparando los conjuntos difusos correspondientes para dos reglas  $i$  y  $k$  utilizando la expresión:

$$F(x_j) = \frac{|A_j^i \wedge A_j^k|}{|A_j^i \vee A_j^k|} \quad (4.4)$$

En ella, un valor  $F(x_j)$  cercano a cero denota una capacidad discriminante alta para la característica evaluada, mientras que un valor próximo a uno identifica un carácter discriminante reducido.

### 4.1.2. Puntuación, ordenación y selección

Para determinar el número de características mínimo que puede formar parte del sistema manteniendo su precisión, se diseña un criterio basado en la acumulación de las puntuaciones obtenidas con respecto a la puntuación total. Las puntuaciones individuales se calculan utilizando ambos, el método estadístico o el criterio difuso. Después, las componentes se ordenan de forma descendente para cada sesión de entrenamiento, y el número mínimo de características candidatas a formar parte del modelo K se calcula como  $K = \min\{k\}$  que cumple:



Figura 4.1: Proceso de creación de la arquitectura S-dFasArt

$$\frac{\sum_{j=1}^k SCORE(j)}{\sum_{j=1}^M SCORE(j)} > \rho \quad (4.5)$$

El parámetro de diseño  $\rho$  se ajusta para descartar cualquier característica cuyo valor SCORE se encuentra bajo el mínimo, y para los cálculos posteriores se sitúa en 0.85.

#### 4.1.3. Selección de características

La selección de características final se realiza aplicando a los datos calculados por el método estadístico o el criterio difuso una de las alternativas siguientes:

1. Selección por Orden. Se determinan los distintos modelos por la selección de un número creciente de características asociado a un orden de relevancia.
2. GMDH. Esta metodología se basa en la definición de un criterio de regularidad (RC) que se calcula para los diferentes modelos candidatos. En este caso, se considera la tasa de acierto medio de los modelos para las seis posibles combinaciones de  $(i, j, k)$   $s_i s_j s_k$  como RC, como muestra la Figura 4.2. Como punto de partida del modelo se toma la componente ofreciendo un RC de mayor valor. A partir de la primera, se vuelve a buscar el modelo con un mayor valor de RC añadiendo a las características ya seleccionadas aquéllas no aún pertenecientes al conjunto. El método añade la componente con mayor RC al conjunto sólo cuando éste es más alto que el de la iteración previa y para en caso contrario, no admitiendo una mayor expansión.

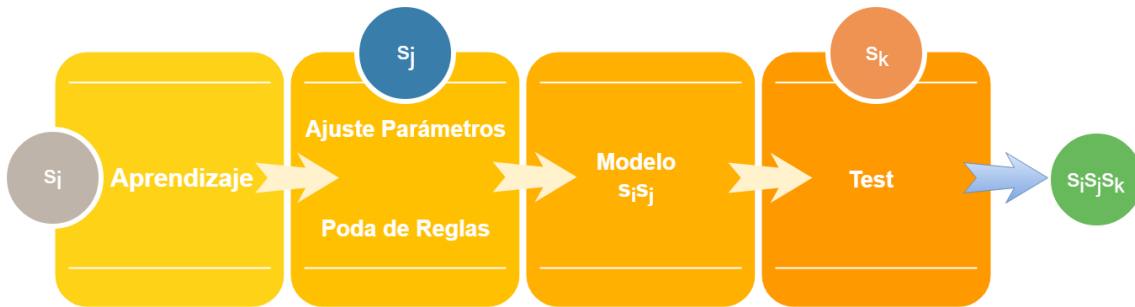


Figura 4.2: Generación de un modelo individual  $s_i s_j s_k$  en la arquitectura S-dFasArt siendo  $s_i$ ,  $s_j$  y  $s_k$  los conjuntos de datos de entrenamiento

## 4.2. Resultados

Esta sección incluye los resultados calculados aplicando la metodología anterior a todas las bases de datos definidas en 3.1.1. Para el primero de los casos, y con el objetivo de exponer de forma detallada el procedimiento propuesto, se presentan cada una de las etapas que componen el proceso de forma exhaustiva. Sin embargo, el resto de las secciones se centran en proveer únicamente los resultados alcanzados.

Es fundamental destacar que la cuarta sesión de datos disponible para cada colaborador sólo se utiliza para comprobar la bondad de las variantes propuestas. Con el objetivo de comprobar la eficiencia de la metodología, se añade una etapa final siguiendo el modelo desarrollado en [135] (Aprendizaje-Poda-Votación) sin ningún ajuste adicional.

Se reproduce la tabla de referencias entre la nomenclatura otorgada a cada conjunto de datos y el conjunto de datos que identifica para facilitar la legibilidad de este capítulo (Tabla 4.1) .

Tabla 4.1: Nomenclatura definida para los conjuntos de datos utilizados en esta tesis doctoral

Identificador	Base de Datos
BCIComp	Datos preprocesados de BCI Competition
BCIEpoc	Datos raw BCI Competition utilizando los canales Emotiv EPOC
EmoEpoc	Datos capturados con Emotiv EPOC - base de datos de 3 usuarios
EasyBCI	Datos obtenidos con Emotiv EPOC - EasyCap canales BCI Competition
EasyEpoc	Datos extraídos con Emotiv EPOC - EasyCap canales Emotiv EPOC
EmoExt	Datos capturados con Emotiv EPOC para una población de 12 usuarios

Del mismo modo, cabe aclarar que los sistemas de selección de características propuestos utilizan de forma nativa la posición de cada componente en el vector preprocesado. Así, los datos BCIComp y EasyBCI forman vectores de 96 columnas (8 sensores x 12 bandas de frecuencia) mientras que para el resto la longitud es de 168 elementos (14 sensores x 12 bandas de frecuencia). Esta aclaración es relevante dado que las Figuras 4.3, 4.4, 4.5 y 4.6 presentan el valor de significancia de cada característica atendiendo a su posición en el vector.

No obstante, y con el propósito de mejorar la legibilidad de los resultados, se convierten todas las componentes obtenidas al formato  $C_f$  donde C representa al canal y  $f$  es la banda de frecuencia de la componente seleccionada utilizando las Tablas 4.2 y 4.3.

### 4.2.1. Datos preprocesados BCI Competition III dataset V

En este apartado se detalla el resultado de aplicar las diferentes combinaciones anteriores a los datos BCI Competition III Dataset V. En primer lugar, se incluye el proceso de cálculo requerido por el método estadístico y ambos la selección por orden y GMDH.

Tabla 4.2: Canal y frecuencia asociadas a cada característica del vector de entrada - Datos en posiciones BCI Competition

Canal	Frecuencia (Hz)											
↓	8	10	12	14	16	18	20	22	24	26	28	30
C3	1	2	3	4	5	6	7	8	9	10	11	12
Cz	13	14	15	16	17	18	19	20	21	22	23	24
C4	25	26	27	28	29	30	31	32	33	34	35	36
CP1	37	38	39	40	41	42	43	44	45	46	47	48
CP2	49	50	51	52	53	54	55	56	57	58	59	60
P3	61	62	63	64	65	66	67	68	69	70	71	72
Pz	73	74	75	76	77	78	79	80	81	82	83	84
P4	85	86	87	88	89	90	91	92	93	94	95	96

Tabla 4.3: Canal y frecuencia asociadas a cada característica del vector de entrada - Datos en posiciones Emotiv EPOC

Canal	Frecuencia (Hz)											
↓	8	10	12	14	16	18	20	22	24	26	28	30
AF3	1	2	3	4	5	6	7	8	9	10	11	12
F7	13	14	15	16	17	18	19	20	21	22	23	24
F3	25	26	27	28	29	30	31	32	33	34	35	36
FC5	37	38	39	40	41	42	43	44	45	46	47	48
T7	49	50	51	52	53	54	55	56	57	58	59	60
P7	61	62	63	64	65	66	67	68	69	70	71	72
O1	73	74	75	76	77	78	79	80	81	82	83	84
O2	85	86	87	88	89	90	91	92	93	94	95	96
P8	97	98	99	100	101	102	103	104	105	106	107	108
T8	109	110	111	112	113	114	115	116	117	118	119	120
FC6	121	122	123	124	125	126	127	128	129	130	131	132
F4	133	134	135	136	137	138	139	140	141	142	143	144
F8	145	146	147	148	149	150	151	152	153	154	155	156
AF4	157	158	159	160	161	162	163	164	165	166	167	168

A continuación, se realiza el procedimiento análogo a partir de la aplicación del criterio difuso.

#### 1. Método estadístico para Selección de Características

La Figura 4.3 muestra los resultados que se obtienen para los tres usuarios del conjunto de datos del BCI Competition. Dado que el problema tratado es tres clases, el valor máximo de  $J(x_j)$  es  $(1/3)^3$ , el cual queda representado por la línea continua en las gráficas. Asimismo, el valor  $J(x_j)$  se calcula de manera independiente para cada componente en cada una de las tres sesiones de entrenamiento. Resulta evidente como la gran mayoría de las características se concentran en posiciones muy cercanas a la línea continua y sólo unas pocas obtienen valores de  $J(x_j)$  más bajos, mostrando una mayor significancia.

Para determinar las componentes más discriminantes, éstas se ordenan de mayor a

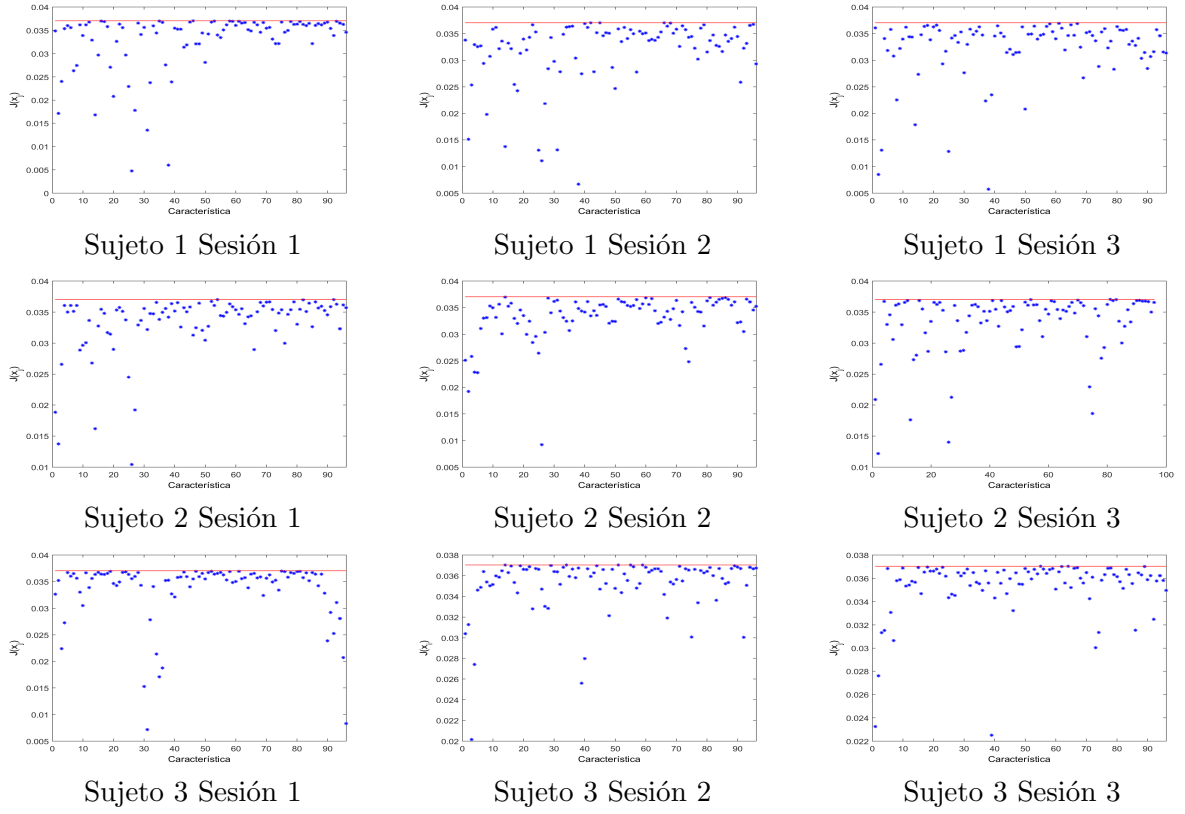


Figura 4.3: Valores  $J(x_j)$  calculados utilizando el método estadístico de selección de características. El valor  $(1/C)^C$  queda representado por la línea continua. Datos BCIComp




Figura 4.4: Representación de la relevancia de cada componente atendiendo a la puntuación obtenida en base a su carácter discriminante. Método estadístico. Datos BCIComp

menor valor de  $J(x_j)$ . Únicamente se consideran las 10 primeras y les es asignada una puntuación de 10 a 1 de acuerdo a la posición alcanzada. La generalización entre las sesiones se realiza sumando las puntuaciones para las características seleccionadas en las tres sesiones de entrenamiento, cuyo resultado se muestra en la Figura 4.4. Como se puede observar, existen componentes que acumulan altas puntuaciones.

Tabla 4.4: Características más relevantes para cada usuario utilizando el método estadístico. Datos BCIComp

Sujeto	1	2	3	4	5	6	7	8	9	10
BCIComp S1	$CP1_{10}$	$C3_{10}$	$Cz_{10}$	$C4_8$	$C4_{10}$	$C4_{20}$	$C4_{12}$	$C3_{12}$	$C3_{22}$	$CP2_{10}$
BCIComp S2	$C4_{10}$	$C3_{10}$	$C3_8$	$C3_{12}$	$Cz_8$	$C4_{12}$	$Cz_{10}$	$Pz_{10}$	$C3_{16}$	$C4_8$
BCIComp S3	$CP1_{12}$	$C3_{12}$	$C3_8$	$C3_{10}$	$C3_{14}$	$C4_{20}$	$P4_{30}$	$C4_{18}$	$P4_{22}$	$C4_{28}$

Tabla 4.5: Tasa de acierto (en %) para el Sujeto 1 en función de la dimensión del vector de entrada (M) aplicando el método estadístico y la selección por orden.  $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp

M	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Media
<b>Sujeto 1</b>							
1	68.25	59.83	68.58	59.78	66.91	67.86	65.20
2	86.24	79.06	87.72	73.48	79.03	75.17	<b>80.12</b>
3	85.96	78.40	85.26	67.66	79.41	69.15	77.64
4	84.84	79.15	87.08	66.80	81.94	65.17	77.50
5	77.05	78.40	79.74	62.44	71.51	64.71	72.31
6	74.52	77.13	79.40	54.30	73.62	66.40	70.90
7	78.17	72.18	80.13	76.63	76.90	74.00	76.34
8	77.66	76.87	80.77	63.88	77.10	78.44	75.79
9	80.10	77.53	81.25	72.65	76.84	77.69	77.68

Se incluyen en la Tabla 4.4 los canales y frecuencias asociados a las 10 componentes más relevantes para cada usuario. El número de características candidatas después de aplicar un  $\rho$  del 85 % son  $K_1 = 9$  para el Sujeto 1,  $K_2 = 10$  para el Sujeto 2 y  $K_3 = 15$  para el Sujeto 3.

■ *Selección por Orden*

Una vez obtenido el número de componentes candidatas, se realizan cálculos de forma iterativa hasta obtener los valores de acierto de cada modelo  $s_i s_j s_k$  para cada una de las mismas. Tomando como ejemplo el Sujeto 1, los resultados de dichos cálculos se recogen en la Tabla 4.5.

En negrita, se puede apreciar como el mayor valor medio se da para un tamaño del vector de entrada de dos componentes. Por tanto, éstas son las seleccionadas, quedando el conjunto  $X_{S1}$  de características seleccionadas compuesto por:

$$X_{S1} = (CP1_{10}, C3_{10})$$



Tabla 4.6: Tasa de acierto (en %) para el Sujeto 2 en función de la dimensión del vector de entrada (M) aplicando el método estadístico y la selección por orden.  $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp

M	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Media
<b>Sujeto 2</b>							
1	44.82	62.56	57.60	46.00	59.09	49.91	53.33
2	62.56	71.44	72.90	67.34	78.91	67.63	70.13
3	68.69	75.43	72.00	68.52	75.98	63.82	<b>70.74</b>
4	61.18	65.08	78.25	65.41	64.53	63.25	66.28
5	67.40	67.33	71.34	55.88	69.97	64.11	66.01
6	62.96	67.45	72.44	65.67	73.76	63.77	67.68
7	61.38	68.37	65.90	58.44	64.61	58.52	62.87
8	62.13	61.34	69.59	53.74	67.88	63.62	63.05
9	62.76	64.58	67.91	56.94	63.28	60.54	62.67
10	62.44	68.14	67.08	56.02	74.57	51.58	63.31

Tabla 4.7: Tasa de acierto (en %) para el Sujeto 3 en función de la dimensión del vector de entrada (M) aplicando el método estadístico y la selección por orden.  $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp

M	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Media
<b>Sujeto 3</b>							
1	38.60	28.27	00.00	42.73	38.61	34.55	30.46
2	42.12	54.23	45.55	45.12	50.85	47.37	47.54
3	42.41	38.00	51.83	45.94	49.15	41.85	44.86
4	40.12	52.75	49.10	47.90	50.38	48.39	48.11
5	41.45	54.91	50.29	49.45	50.47	48.60	49.20
6	43.43	50.55	48.31	49.04	55.75	56.92	<b>50.67</b>
7	42.06	50.32	47.30	47.37	54.47	49.53	48.51
8	40.64	48.31	44.39	45.74	50.15	49.36	46.43
9	42.35	53.27	44.88	44.16	49.85	47.78	47.05
10	40.55	58.97	43.08	44.92	53.65	50.00	48.53
11	46.05	51.29	44.27	41.91	52.95	51.66	48.02
12	47.91	54.96	44.59	50.03	48.10	54.47	50.01
13	46.69	50.73	46.48	45.71	50.64	52.25	48.75
14	44.27	55.34	50.73	48.16	44.71	52.69	49.32
15	42.59	47.75	44.30	50.82	49.47	51.52	47.74

Aplicando el procedimiento análogo al Sujeto 2, el método estadístico alcanza las tasas de acierto mostradas en la Tabla 4.6. Se puede apreciar que la mayor precisión se consigue para la tercera componente del vector, por lo que las características seleccionadas son:

$$X_{S2} = (C4_{10}, C3_{10}, C3_8)$$

Finalmente, aplicando idéntica metodología se obtienen los datos recogidos en la Tabla 4.7, siendo en este caso las características seleccionadas:

$$X_{S3} = (CP1_{12}, C3_{12}, C3_8, C3_{10}, C3_{14}, C4_{20})$$

■ *Selección GMDH*

La Tabla 4.8 muestra los resultados para los modelos seleccionados y sus valores RC.


Tabla 4.8: Características y valores RC para los diferentes usuarios basados en una selección GMDH para datos puntuados utilizando el método estadístico. Datos BCIComp

Características	RC
<b>Sujeto 1</b>	
$(CP1_{10})$	67.96
$(CP1_{10}, C3_{10})$	80.12
$(CP1_{10}, C3_{10}, C4_{20})$	<b>80.95</b>
<b>Sujeto 2</b>	
$(C3_{10})$	57.22
$(C3_{10}, C4_{10})$	70.13
$(C3_{10}, C4_{10}, C3_{16})$	<b>72.72</b>
<b>Sujeto 3</b>	
$(C3_{14})$	49.58
$(C3_{14}, C3_{12})$	51.70
$(C3_{14}, C3_{12}, C4_{18})$	<b>53.34</b>


## 2. Criterio difuso de Selección de Características

La Figura 4.5 presenta una comparación del carácter discriminante de las características para los tres usuarios utilizando la sesión 1 para el aprendizaje y la 2 para el ajuste y la poda de reglas. Cabe destacar que el resto de las combinaciones posibles entre las sesiones de entrenamiento y ajuste alcanzan resultados análogos.


En este caso se ordenan las componentes de mayor a menor valor de  $F(x_j)$  seleccionando únicamente las 10 de mayor importancia (Figura 4.6). Éstas se obtienen




Sujeto 1 Izquierda vs. Derecha




Sujeto 1 Izquierda vs. Palabra




Sujeto 1 Derecha vs. Palabra




Sujeto 2 Izquierda vs. Derecha




Sujeto 2 Izquierda vs. Palabra




Sujeto 2 Derecha vs. Palabra



Sujeto 3 Izquierda vs. Derecha




Sujeto 3 Izquierda vs. Palabra




Sujeto 3 Derecha vs. Palabra


Figura 4.5: Valores  $F(x_j)$  calculados utilizando el criterio difuso para los tres usuarios utilizando la sesión 1 como entrenamiento y la 2 para el ajuste de parámetros y la poda de reglas. Datos BCIComp



Sujeto 1



Sujeto 2



Sujeto 3

Figura 4.6: Representación de la relevancia de cada componente atendiendo a la puntuación obtenida en base a su carácter discriminante. Criterio difuso. Datos BCIComp

tomando como criterio la puntuación conseguida a partir de la suma de las puntuaciones individuales otorgadas en cada uno de los seis modelos S-dFasArt. El criterio, al igual que en casos anteriores, se basa en seleccionar las 10 características más discriminantes para cada uno de ellos y en puntuarlas de 1 a 10, asignando a la

Tabla 4.9: Características más relevantes para cada usuario utilizando el criterio difuso. Se definen como  $C_f$  donde C representa al canal y  $f$  es la banda de frecuencia seleccionada. Datos BCIComp

Sujeto	1	2	3	4	5	6	7	8	9	10
BCIComp S1	$C4_{10}$	$C4_{12}$	$C4_8$	$CP1_{10}$	$C3_{10}$	$C3_{12}$	$P3_8$	$CP1_{12}$	$P3_{10}$	$Cz_{10}$
BCIComp S2	$C3_{10}$	$C4_{10}$	$C3_8$	$C4_8$	$Pz_{10}$	$C4_{12}$	$C3_{12}$	$Cz_{10}$	$Pz_8$	$Cz_8$
BCIComp S3	$C3_{12}$	$Pz_{10}$	$CP1_{12}$	$C3_{14}$	$Pz_8$	$C4_{12}$	$C4_8$	$C3_8$	$P4_{10}$	$C4_{10}$

Tabla 4.10: Tasa de acierto (en %) para el Sujeto 1 en función de la dimensión del vector de entrada (M) aplicando el criterio difuso y la selección por orden.  $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp

M	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Media
<b>Sujeto 1</b>							
1	49.78	55.62	39.27	40.54	54.21	58.60	49.67
2	56.98	66.04	60.17	55.39	70.28	71.65	63.42
3	65.30	60.17	65.98	59.32	67.40	59.46	62.94
4	78.08	73.73	78.78	65.14	74.02	70.53	73.38
5	78.76	73.44	80.47	78.35	77.45	69.58	76.34
6	79.71	70.19	80.63	76.86	77.85	65.97	75.20
7	79.23	78.51	78.62	58.97	79.98	68.15	73.91
8	79.07	77.79	79.48	71.62	76.50	69.47	75.66
9	80.30	79.00	80.04	66.37	81.08	81.07	<b>77.98</b>

componente más significativa el mayor valor. Cuando se aplica el criterio  $\rho$  superior al 85 % para seleccionar el valor de K, se obtiene  $K_1 = 9$  (Sujeto 1),  $K_2 = 11$  (Sujeto 2) and  $K_3 = 16$  (Sujeto 3). Las características más discriminantes para cada usuario se recogen en la Tabla 4.9.

■ *Selección por Orden*

De igual modo que en el caso estadístico, la Tabla 4.10 muestra el rendimiento máximo calculado para el Sujeto 1 aplicando la selección por orden. En este caso se alcanza para  $K_1 = 9$ , con un valor medio del 77.98 %. Por tanto, se seleccionan todas las componentes candidatas:

$$X_{S1} = (C4_{10}, C4_{12}, C4_8, CP1_{10}, C3_{10}, C3_{12}, P3_8, CP1_{12}, P3_{10})$$

Para el Sujeto 2 se pasa de 11 componentes candidatas ( $K_2 = 11$ ) a 3 con una precisión máxima del 70.34 %, tal y como muestra la Tabla 4.11, siendo éstas:

Tabla 4.11: Tasa de acierto (en %) para el Sujeto 2 en función de la dimensión del vector de entrada (M) aplicando el criterio difuso y la selección por orden.  $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp

M	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Media
<b>Sujeto 2</b>							
1	34.48	58.33	65.87	66.07	60.94	57.63	57.22
2	62.56	71.44	72.90	67.34	78.91	67.63	70.13
3	68.69	75.43	72.00	68.52	75.98	63.82	<b>70.74</b>
4	61.43	63.31	70.56	59.50	69.53	62.33	64.44
5	61.46	70.05	67.17	59.65	63.54	53.74	62.60
6	58.06	69.70	72.87	58.41	61.83	62.07	63.83
7	68.03	65.74	65.84	58.38	45.60	61.95	60.92
8	65.01	62.24	50.60	43.98	70.95	58.67	58.58
9	68.15	66.20	62.41	48.10	66.30	58.64	61.63
10	65.67	66.41	65.15	63.59	66.26	56.45	63.92
11	52.33	67.36	68.63	58.27	56.57	55.90	59.84

Tabla 4.12: Tasa de acierto (en %) para el Sujeto 3 en función de la dimensión del vector de entrada (M) aplicando el criterio difuso y la selección por orden.  $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp

M	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Media
<b>Sujeto 3</b>							
1	42.50	54.61	34.65	46.41	54.47	45.59	46.37
2	41.28	36.01	40.17	46.82	49.97	46.82	43.51
3	43.87	48.60	44.22	46.90	48.01	46.06	46.28
4	44.39	53.21	41.95	48.83	51.26	48.48	48.02
5	45.17	54.38	42.88	44.89	53.91	49.45	<b>48.45</b>
6	42.67	51.26	43.90	47.14	56.89	47.20	48.18
7	39.85	56.75	41.10	42.73	48.57	44.57	45.60
8	41.16	54.56	43.69	46.73	45.39	45.59	46.19
9	42.03	50.29	40.38	43.55	46.47	45.85	44.76
10	41.31	50.32	38.75	43.43	44.10	38.70	42.77
11	40.32	45.97	38.49	48.16	44.71	44.60	43.71
12	41.19	50.18	44.62	41.44	42.79	45.24	44.24
13	42.01	44.80	36.31	42.03	44.92	41.65	41.96
14	41.69	47.81	41.69	47.96	45.74	41.44	44.39
15	41.42	51.90	39.22	46.99	42.41	43.05	44.17
16	40.23	41.12	37.65	43.49	39.08	43.87	40.91

$$X_{S2} = (C4_{10}, C3_{10}, C3_8)$$

Finalmente, para el Sujeto 3, realizando los cálculos mostrados en la Tabla 4.12, se reduce el número total de características candidatas desde  $K_3 = 16$  a 4, que son:

$$X_{S3} = (C3_{12}, Pz_{10}, CP1_{12}, C3_{14}, Pz_8)$$

■ *Selección GMDH*

Nuevamente, se utiliza el método GMDH para seleccionar aquellas componentes más relevantes del vector de características candidatas. En la Tabla 4.13 se muestran tanto el proceso de selección como las componentes que son finalmente escogidas.

Tabla 4.13: Características y valores de RC para los modelos calculados de los diferentes usuarios basado en selección GMDH para datos puntuados basados en el criterio difuso. Datos BCIComp

Características	RC
<b>Sujeto 1</b>	
$(CP1_{10})$	67.96
$(CP1_{10}, C3_{10})$	80.12
$(CP1_{10}, C3_{10}, C4_{12})$	80.77
$(CP1_{10}, C3_{10}, C4_{12}, P3_{10})$	<b>82.22</b>
<b>Sujeto 2</b>	
$(C3_{10})$	57.22
$(C3_{10}, C4_{10})$	70.13
$(C3_{10}, C4_{10}, C4_{12})$	70.89
$(C3_{10}, C4_{10}, C4_{12}, P3_8)$	<b>71.54</b>
<b>Sujeto 3</b>	
$(C3_{14})$	49.58
$(C3_{14}, C3_{12})$	51.70
$(C3_{14}, C3_{12}, CP2_8)$	<b>52.41</b>

### 3. Discusión

En los apartados anteriores se ha detallado paso a paso la aplicación de la metodología de selección de características aportada sobre cada uno de los conjuntos de datos, sin analizar los mismos. En éste se evalúan las diferentes combinaciones para cada usuario y se profundiza en las tendencias preliminares identificadas.

Se puede apreciar que se encuentra para todos los sujetos un conjunto de componentes que mejora la precisión inicial alcanzada con el conjunto completo. Además, se puede observar como se podría operar un sistema BCI con similares niveles de

Tabla 4.14: Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos BCIComp

Método de selección	Modelo	Tasa Acierto	No	%
<b>BCIComp Sujeto 1</b>				
Ninguno	(...)	87.21	96	100.00
Estadístico + Orden	( $CP_{10}, C_{30}$ )	85.39	2	2.08
Estadístico + GMDH	( $CP_{10}, C_{30}, C_{40}$ )	87.64	3	3.13
Difuso + Orden	( $C_{40}, C_{42}, C_{48}, CP_{10}, C_{30}, C_{32}, P_{38}, CP_{12}, P_{30}$ )	<b>89.95</b>	9	9.38
Difuso + GMDH	( $CP_{10}, C_{30}, C_{42}, P_{30}$ )	89.50	4	4.17
<b>BCIComp Sujeto 2</b>				
Ninguno	(...)	82.26	96	100.00
Estadístico + Orden	( $C_{40}, C_{30}, C_{38}$ )	81.80	3	3.13
Estadístico + GMDH	( $C_{30}, C_{40}, C_{36}$ )	81.57	3	3.13
Difuso + Orden	( $C_{40}, C_{30}, C_{38}$ )	81.80	3	3.13
Difuso + GMDH	( $C_{30}, C_{40}, C_{42}, P_{38}$ )	<b>82.49</b>	4	4.17
<b>BCIComp Sujeto 3</b>				
Ninguno	(...)	58.72	96	100.00
Estadístico + Orden	( $CP_{12}, C_{32}, C_{38}, C_{30}, C_{34}, C_{40}$ )	57.57	6	6.25
Estadístico + GMDH	( $C_{34}, C_{32}, C_{48}$ )	<b>59.40</b>	3	3.13
Difuso + Orden	( $C_{32}, P_{30}, CP_{12}, C_{34}, P_{38}$ )	52.52	5	5.21
Difuso + GMDH	( $C_{34}, C_{32}, CP_{28}$ )	57.80	3	3.13
<b>BCIComp Media</b>				
Ninguno		76.06	96.00	100.00
Estadístico + Orden		74.92	3.67	3.82
Estadístico + GMDH		76.21	3.00	3.13
Difuso + Orden		74.76	5.67	5.91
Difuso + GMDH		<b>76.6</b>	3.67	3.82

Tabla 4.15: Canales y frecuencias seleccionadas aplicando el criterio difuso + GMDH. Se denotan como  $\odot$  aquellas características seleccionadas por un sujeto, como  $\oslash$  las seleccionadas por dos y como  $\otimes$  las seleccionadas por todos ellos. Datos BCIComp

H <sub>z</sub> →	8	10	12	14	16	18	20	22	24	26	28	30
C3	.	$\oslash$	.	.	.	.	.	.	.	.	.	.
Cz	.	.	.	.	.	.	.	.	.	.	.	.
C4	.	$\odot$	$\oslash$	.	.	.	.	.	.	.	.	.
CP1	.	$\odot$	.	.	.	.	.	.	.	.	.	.
CP2	$\odot$	.	.	.	.	.	.	.	.	.	.	.
P3	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.	.
Pz	.	.	$\odot$	$\odot$	.	.	.	.	.	.	.	.
P4	.	.	.	.	.	.	.	.	.	.	.	.
<b>Total</b>	2	5	3	1	.	.	.	.	.	.	.	.

acierto a los mejores presentados con entre tres y nueve características, lo que supone utilizar únicamente entre un 3.13 % y un 9.38 % de la capacidad de procesamiento requerida inicialmente.

Para este conjunto de usuarios no se pueden encontrar tendencias claras relacionadas con la bondad de una aproximación sobre las demás. Cuando se revisan los datos medios aparecen variaciones que se podrían considerar mínimas entre las diferentes alternativas, encontrándose todas ellas en un rango de dos puntos. No obstante, la metodología que produce un mejor rendimiento es la combinación del criterio difuso y la selección GMDH, que supera el acierto de clasificación medio obtenido utilizando todas las características para los tres usuarios.

Igualmente, resulta evidente a partir de la Tabla 4.14 la existencia de un subconjunto de características que aparecen en todos los métodos de selección para un determinado usuario. Por ejemplo, las características  $CP1_{10}$  y  $C3_{10}$  son comunes a todos los modelos para el Sujeto 1, mientras que  $C4_{10}$  y  $C3_{10}$  se incluyen siempre para el Sujeto 2 y  $C3_{12}$  y  $C3_{14}$  para el Sujeto 3.

Sin embargo, no es posible generalizar un conjunto de características válido para todos los usuarios. Los resultados muestran como  $C3_{10}$  aparece en todos los métodos para los Sujetos 1 y 2, pero no forma parte del conjunto de características seleccionadas para el Sujeto 3 por los métodos de selección difusa. Igualmente, es ciertamente difícil encontrar características comunes a todos los casos incluso a partir del mismo método de selección. Como ejemplo, para la aproximación basada en el criterio difuso + GMDH se seleccionan  $C3_{10}$  y  $C4_{12}$  para los Sujetos 1 y 2, pero no parece que tengan relevancia para el Sujeto 3.

Atendiendo ahora al canal seleccionado, se puede establecer que las posiciones destacadas no sólo se localizan en la área lateral de la corteza motora, sino que también aparecen en la zona central entre ellas. La Tabla 4.15, que incluye todas las características relevantes como resultado de la combinación difusa+GMDH en la elección de componentes, muestra claramente que casi todas ellas pertenecen a los ritmos  $\mu$ , entre 8 y 12Hz. Del mismo modo, la importancia de la posición C3 es común a todos los usuarios, mientras que C4 únicamente parece ser notable para los Sujetos 1 y 2. Además, otros canales y frecuencias también muestran ser significativos. Por ejemplo, las bandas  $\mu$  de las posiciones CP1 y CP2 son relevantes para los Sujetos 1 y 3, mientras que estos mismos ritmos son importantes en la posición P3 para los Sujetos 1 y 2.

Finalmente, se muestra en la Tabla 4.16 la distribución de la tasa de acierto entre las diferentes tareas utilizando cada una de las variantes propuestas de selección de características. Se puede apreciar para los Sujetos 1 y 2 que la capacidad del clasificador de predecir las tareas Izquierda -  $I$  y Derecha -  $D$  se homogeneiza para la variante ganadora. Por ejemplo, para el Sujeto 1 predecir  $D$  mejora del 78.91 % al 90.63 %, mientras que la precisión de  $I$  se mantiene en el 92.31 % para la combinación entre el criterio difuso y la selección por orden. Lo mismo ocurre para el Sujeto 2, si bien en este caso ambas crecen desde 81.25 % y 77.78 % hasta 88.19 % y 87.04 %



Tabla 4.16: Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos preprocesados BCI Competition III dataset V mostrados como %

Método de selección	Global	Motor	Derecha	Izquierda	Palabra
<b>BCIComp Sujeto 1</b>					
Todas características	87.67	92.47	78.91	92.31	90.56
Estadístico + Orden	85.39	90.64	85.16	73.85	93.89
Estadístico + GMDH	87.67	92.47	82.03	86.92	92.22
Difuso + Orden	<b>89.95</b>	92.69	90.63	92.31	87.78
Difuso + GMDH	89.50	92.92	90.63	86.92	90.56
<b>BCIComp Sujeto 2</b>					
Todas características	82.26	88.02	81.25	77.78	85.71
Estadístico + Orden	81.80	86.64	82.64	83.33	80.22
Estadístico + GMDH	81.57	86.64	80.56	83.33	81.32
Difuso + Orden	81.80	86.64	82.64	83.33	80.22
Difuso + GMDH	<b>82.49</b>	87.10	88.19	87.04	75.27
<b>BCIComp Sujeto 3</b>					
Todas características	58.72	75.23	73.97	24.00	80.00
Estadístico + Orden	57.57	80.05	81.51	24.00	68.57
Estadístico + GMDH	<b>59.40</b>	80.73	73.97	29.33	76.43
Difuso + Orden	52.52	78.44	73.29	19.33	66.43
Difuso + GMDH	57.80	81.42	69.18	25.33	80.71
<b>BCIComp Media</b>					
Todas características	76.22	85.24	78.04	64.70	85.42
Estadístico + Orden	74.92	85.78	83.10	60.39	80.89
Estadístico + GMDH	76.21	86.61	78.85	66.53	83.32
Difuso + Orden	74.76	85.92	82.19	64.99	78.14
Difuso + GMDH	<b>76.60</b>	87.15	82.67	66.43	82.18

respectivamente para las tareas  $D$  e  $I$  a partir de la selección por criterio difuso y GMDH. Para el Sujeto 3 también se reduce la diferencia entre la capacidad del sistema de predecir ambas tareas, sin embargo, es tan alta la misma en los datos iniciales que no se pueden nivelar ambas.

En términos generales el mayor rendimiento se consigue en la tarea predecir  $D$ , que es la acertada con mayor precisión para las componentes seleccionadas a partir del método estadístico y la selección por orden, además de las variantes basadas en el criterio difuso. Muy de cerca se establece la capacidad del sistema de predecir Palabra -  $P$ , ambas en torno al 80 % para todas las combinaciones. Sin embargo, el nivel de acierto prediciendo  $I$  muestra un comportamiento mucho más modesto, también probablemente derivado del valor bajo de precisión inicial para el Sujeto 3.

#### 4.2.2. Datos BCI Competition III dataset V - Posiciones Emotiv

El conjunto de datos BCI Competition III dataset V en las posiciones Emotiv (BCIE-poc) muestra un comportamiento diferente, siendo metodologías de selección distintas las que alcanzan un mayor acierto en la clasificación para cada sujeto.

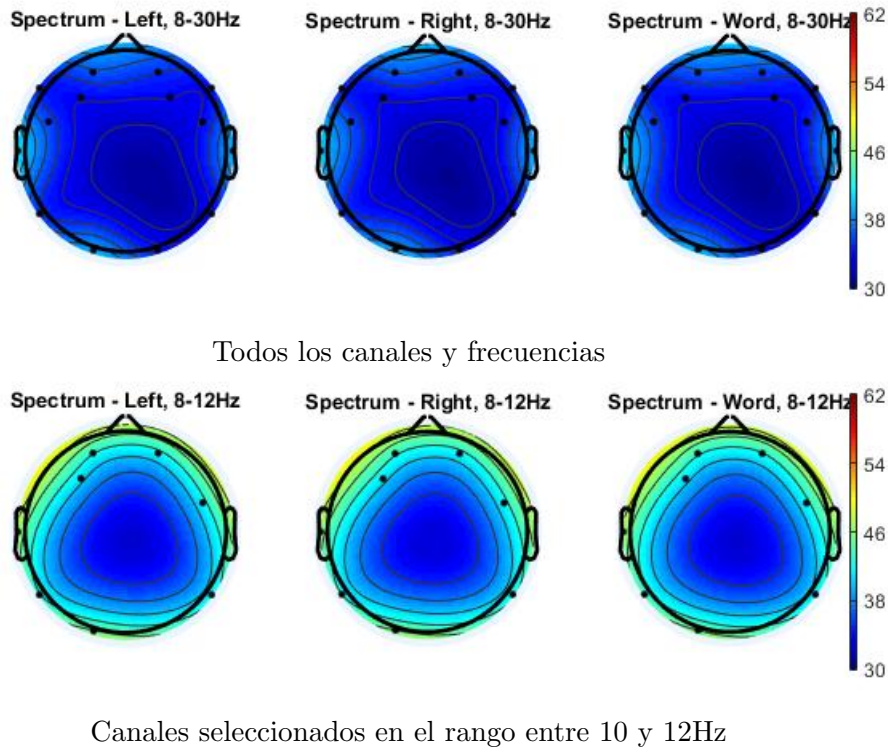


Figura 4.7: BCIEpoc Sujeto 1 - Distribución espectral de potencia en las posiciones Emotiv EPOC

Para el Sujeto 1, la aproximación ganadora es la formada por la combinación entre el criterio de búsqueda difuso y la selección por orden. Para este caso, el acierto conseguido alcanza el 64.48 % utilizando únicamente 16 características distribuidas entre ocho diferentes sensores (AF3, P7, AF4, O1, T7, P8, F3 y FC6), superando el 63.40 % logrado utilizando el conjunto total de 96. En la Figura 4.7, que muestra la distribución espectral para cada una de las tareas llevadas a cabo de forma separada, se puede observar que cuando se utilizan todas las componentes disponibles la concentración de potencia resulta homogénea, con algo más de energía en el área frontal, la corteza motora y en el área occipital izquierda del cerebro. Esta tendencia se confirma al filtrar la señal en la banda de frecuencias entre 8 y 12Hz para las posiciones seleccionadas.

Para el Sujeto 2, la búsqueda difusa con selección GMDH es la más precisa logrando un rendimiento del 57.81 %, que queda por debajo del 59.07 % alcanzado por el conjunto total. No obstante, la reducción es mucho mayor que en el caso del Sujeto 1 en cuanto al número de componentes, ya que con un 4.17 % de las características se alcanza un acierto únicamente alrededor de un punto menor al logrado con el conjunto total de 96 datos, si bien éstas pertenecen a cinco posiciones diferentes. Es decir, desde la perspectiva de fabricación de un sistema con un mínimo número de electrodos este usuario requeriría un dispositivo EEG con menos electrodos (de ocho a cinco) y alrededor de la mitad de

Tabla 4.17: Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos BCIEpoc

Método de selección	Modelo	Tasa Acierto	No	%
<b>BCIEpoc Sujeto 1</b>				
Ninguno	(...)	63.40	168	100.00
Estadístico + Orden	( $P7_{10}, T8_{20}, T8_{22}, P7_{12},$ $FC6_8, AF3_8, T8_{18}$ )	59.79	7	4.17
Estadístico + GMDH	( $F3_{10}, P7_{10}, T8_{22},$ $FC6_8, AF3_8, T8_{18}$ )	63.62	5	2.98
Difuso + Orden	( $AF3_8, P7_8, P7_{10}, AF4_8, P7_{12},$ $O1_8, AF3_{10}, T7_8, O1_{10}, AF4_{10},$ $P8_8, O1_{12}, F3_{10}, P8_{10}, O1_{14},$ $FC6_8$ )	<b>64.47</b>	16	9.52
Difuso + GMDH	( $F3_{10}, P7_{10}, T8_8, T7_8$ )	59.79	4	2.38
<b>BCIEpoc Sujeto 2</b>				
Ninguno	(...)	59.07	168	100.00
Estadístico + Orden	( $FC5_8, F7_{30}, F7_{28}, F3_{12}, FC5_{16},$ $F7_{26}, F3_{18}, F3_{30}$ )	40.93	11	6.55
Estadístico + GMDH	( $FC5_{14}, F3_{10}, FC5_{18},$ $F3_{10}, FC5_{14}, F3_{20},$ $F3_{18}, FC5_{16}, FC5_{18}$ )	55.06	6	3.57
Difuso + Orden	( $P8_{10}, P8_8, P7_{10}, P8_{12}, P7_8,$ $P7_{12}, O1_{10}, T7_{10}, T8_{10}, T7_8,$ $O2_{10}, O1_8, O2_8, F7_{26}, T8_8,$ $F7_{28}, AF3_8$ )	54.85	17	10.12
Difuso + GMDH	( $F3_{10}, T7_8, T7_{10}, P7_{12},$ $P8_{12}, F7_{18}, F7_{30}$ )	<b>57.81</b>	7	4.17
<b>BCIEpoc Sujeto 3</b>				
Ninguno	(...)	42.23	168	100.00
Estadístico + Orden	( $AF3_{30}, T8_8, FC6_{30}, AF3_{28}, T8_{10},$ $FC6_{28}, AF3_{26}, T8_{12}, FC6_{26}, T7_{22},$ $T8_{14}, F8_{30}, AF3_{24}, T8_{16}, T8_{30},$ $AF3_{22}, FC5_8, T8_{28}$ )	34.45	18	10.71
Estadístico + GMDH	( $FC5_8$ )	<b>44.12</b>	1	0.78
Difuso + Orden	( $O1_{10}, O1_{12}, P8_8, P8_{10}, O2_{10},$ $O1_{12}, O2_8, P8_{12}, O2_{12}, AF3_8,$ $O1_{14}, O2_{14}, P8_{14}, AF4_8, T7_{20},$ $FC5_8, P7_{10}, T8_{14}, T7_{30}, T8_{12},$ $T8_{16}$ )	34.24	21	12.5
Difuso + GMDH	( $FC5_8, O2_{16}, T8_{12}$ )	39.92	3	1.79
<b>BCIEpoc Media</b>				
Ninguno		54.90	168.00	100.00
Estadístico + Orden		45.06	12	7.14
Estadístico + GMDH		<b>54.27</b>	4	2.38
Difuso + Orden		51.19	18	10.71
Difuso + GMDH		52.51	4.67	2.78

capacidad de cómputo (desde 16 características a siete).

Por último, el caso del Sujeto 3 resulta curioso ya que se parte de una tasa de acierto muy baja, en concreto de un 42.23 %, que se supera finalmente (44.12 %) seleccionando

Tabla 4.18: Canales y frecuencias seleccionadas aplicando el método estadístico + GMDH. Se denotan como  $\odot$  aquellas características seleccionadas por un sujeto, como  $\oslash$  las seleccionadas por dos y como  $\otimes$  las seleccionadas por todos ellos. Datos BCIEpoc

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
AF3	$\odot$	.	.	.	.	.	.	.	.	.	.	.
F7	.	.	.	.	.	.	.	.	.	.	.	.
F3	.	$\oslash$	.	.	.	$\odot$	$\odot$	.	.	.	.	.
FC5	$\odot$	.	.	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.
T7	.	.	.	.	.	.	.	.	.	.	.	.
P7	.	$\odot$	.	.	.	.	.	.	.	.	.	.
O1	.	.	.	.	.	.	.	.	.	.	.	.
O2	.	.	.	.	.	.	.	.	.	.	.	.
P8	.	.	.	.	.	.	.	.	.	.	.	.
T8	.	.	.	.	.	$\odot$	.	$\odot$	.	.	.	.
FC6	$\odot$	.	.	.	.	.	.	.	.	.	.	.
F4	.	.	.	.	.	.	.	.	.	.	.	.
F8	.	.	.	.	.	.	.	.	.	.	.	.
AF4	.	.	.	.	.	.	.	.	.	.	.	.
<b>Total</b>	<b>3</b>	<b>3</b>	.	<b>1</b>	<b>1</b>	<b>3</b>	<b>1</b>	<b>1</b>	.	.	.	.

únicamente la componente  $FC5_8$  del vector de características.

Para cada usuario funciona mejor una variante distinta de la metodología presentada: criterio difuso junto a selección por orden para el Sujeto 1, criterio difuso combinado con selección GMDH para el Sujeto 2 y método estadístico asociado a selección GMDH para el Sujeto 3. Además los rangos de precisión entre la mejor y peor opción para cada colaborador son muy cambiantes. Por ejemplo, para el Sujeto 1 la diferencia entre éstas se sitúa en torno a cinco puntos, para el Sujeto 2 la diferencia alcanza prácticamente 17 puntos, mientras que para el Sujeto 3 se encuentran en torno a 10 puntos de fluctuación.

En media, la aproximación ofreciendo un mejor rendimiento del sistema incluye una elección basada en un modelo estadístico y una selección GMDH. Cabe destacar que los resultados para el Sujeto 3 condicionan este resultado, puesto que esta aproximación supera en torno a 10 puntos a las metodologías incluyendo una selección por orden y en alrededor de cinco a la combinación del criterio difuso con GMDH.

Al contrario que en el caso anterior, sólo se pueden encontrar características seleccionadas por todas las diferentes variantes de la metodología presentada para los Sujetos 1 y 3, y éstas son  $P7_{10}$  y  $FC5_8$  respectivamente. Sin embargo, no resulta posible encontrar ningún conjunto de características común para el Sujeto 2. En este caso,  $F3_{18}$  no queda entre las componentes escogidas para el criterio difuso con selección por orden y  $F7_{28}$  o  $F7_{30}$  sólo son seleccionadas en dos de las aproximaciones.

En la Tabla 4.18 se muestra la distribución frecuencial de las componentes seleccionadas por el método estadístico y la selección GMDH, que es la variante que proporciona un mayor acierto medio. Como se puede apreciar, el conjunto elegido se encuentra en mayor medida en las bandas de 8 y 10Hz con un pico en la banda de 18Hz.

Finalmente, se incluye en la Tabla 4.19 una comparación de la distribución del acierto

Tabla 4.19: Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos BCI Competition III dataset V seleccionando las posiciones disponibles en Emotiv EPOC mostrados como %

Método de selección	Global	Motor	Derecha	Izquierda	Palabra
<b>BCIEpoc Sujeto 1</b>					
Todas características	63.40	83.19	93.57	19.72	73.94
Estadístico + Orden	59.79	76.38	73.57	28.17	73.40
Estadístico + GMDH	63.62	81.70	44.29	71.13	72.34
Difuso + Orden	<b>64.47</b>	80.43	74.29	35.92	78.72
Difuso + GMDH	59.79	79.36	81.43	9.15	81.91
<b>BCIEpoc Sujeto 2</b>					
Todas características	59.07	68.35	46.25	25.83	90.21
Estadístico + Orden	40.93	40.93	0.00	0.00	1.00
Estadístico + GMDH	55.06	62.24	57.50	0.00	87.11
Difuso + Orden	54.85	65.40	28.13	33.33	90.21
Difuso + GMDH	<b>57.81</b>	68.14	47.50	25.00	86.60
<b>BCIEpoc Sujeto 3</b>					
Todas características	42.23	59.45	32.72	26.58	67.95
Estadístico + Orden	34.45	38.66	0.00	17.72	87.18
Estadístico + GMDH	<b>44.12</b>	65.97	0.00	78.48	55.13
Difuso + Orden	34.24	46.43	32.72	1.90	68.59
Difuso + GMDH	39.92	49.58	0.00	32.91	88.46
<b>BCIEpoc Media</b>					
Todas características	54.90	70.33	57.51	24.04	77.37
Estadístico + Orden	45.06	51.99	24.52	15.30	53.86
Estadístico + GMDH	<b>54.27</b>	69.97	33.93	49.87	71.53
Difuso + Orden	51.19	64.09	45.05	23.72	79.17
Difuso + GMDH	52.51	65.69	42.98	22.35	85.66

alcanzado durante la etapa de clasificación para cada usuario. De ella se puede extraer que para el Sujeto 1, cuya tasa de acierto inicial es la mayor para este conjunto de datos, sólo la variante formada por el criterio difuso y la selección GMDH mantiene la diferencia inicial entre las tareas motoras Izquierda - *I* y Derecha - *D*. Sin embargo, esta variación disminuye para el resto de combinaciones manteniendo la precisión de la predecir Palabra - *P*, siendo en el mejor de los casos aún de casi 27 puntos para el método estadístico con selección GMDH.

Sin embargo, para el Sujeto 2 y el 3 se invierte el fenómeno anterior y se puede comprobar que el clasificador deja de predecir uno de los estados motores para predecir únicamente el otro. Este es el caso con Izquierda - *I* para la selección por el método estadístico para el Sujeto 2. Respecto al Sujeto 3, el resultado es aún más evidente en este aspecto dado que todas las componentes seleccionadas por los diferentes algoritmos se comportan de forma análoga, reduciendo a cero la capacidad de predecir uno de los estados motores.

#### 4.2.3. Datos capturados con Emotiv EPOC

Revisando los resultados obtenidos repitiendo el análisis sobre los datos capturados con Emotiv EPOC (EmoEpoc) se puede apreciar que la selección de características únicamente

Tabla 4.20: Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos EmoEpoc

Método de selección	Modelo	Tasa Acierto	No	%
<b>EmoEpoc Sujeto 1</b>				
Ninguno	(...)	69.04	168	100.00
Estadístico + Orden	( $F_{818}, F_{820}, O_{28}, P_{88}, P_{810}, F_{88}, FC_{528}, P_{812}$ )	63.39	8	4.76
Estadístico + GMDH	( $O_{28}, P_{812}, FC_{530}$ )	<b>67.78</b>	3	1.79
Difuso + Orden	( $F_{88}, F_{78}, P_{88}, AF_{38}, O_{110}, T_{78}, F_{810}, P_{810}, O_{18}, FC_{58}, AF_{48}, P_{812}, F_{812}, P_{78}, T_{88}, P_{814}, O_{112}, FC_{510}, P_{710}, AF_{310}, AF_{410}$ )	66.11	21	12.50
Difuso + GMDH	( $P_{78}, P_{810}, P_{812}, T_{78}, F_{78}, AF_{320}$ )	<b>67.78</b>	6	3.57
<b>EmoEpoc Sujeto 2</b>				
Ninguno	(...)	63.50	168	100.00
Estadístico + Orden	( $F_{824}, F_{316}, T_{88}, FC_{622}, AF_{48}, T_{78}, FC_{626}, AF_{410}, T_{810}, F_{822}, F_{826}, AF_{412}, T_{812}, FC_{628}, F_{820}, AF_{414}$ )	34.56	16	9.52
Estadístico + GMDH	( $FC_{624}, T_{812}, FC_{622}$ )	41.25	3	1.79
Difuso + Orden	( $F_{830}, F_{818}, F_{828}, F_{816}, F_{820}, F_{826}, F_{814}, P_{724}, F_{822}, F_{824}, P_{726}, P_{722}, P_{720}, FC_{630}, P_{728}, P_{730}, T_{720}, FC_{628}, FC_{626}, P_{718}, T_{718}, FC_{620}$ )	<b>54.21</b>	22	13.10
Difuso + GMDH	( $P_{726}, FC_{628}, FC_{622}, FC_{626},$	44.06	4	2.38
<b>EmoEpoc Sujeto 3</b>				
Ninguno	(...)	55.29	168	100.00
Estadístico + Orden	( $T_{78}, FC_{610}, F_{88}, T_{710}, FC_{68}, F_{810}, T_{718}, FC_{612}, F_{812}, T_{720}, FC_{614}$ )	38.23	11	6.55
Estadístico + GMDH	( $F_{812}, FC_{612}, FC_{616}$ )	39.09	3	1.79
Difuso + Orden	( $P_{810}, P_{88}, O_{210}, FC_{68}, F_{78}, O_{212}, F_{88}, P_{812}, F_{810}, F_{710}, FC_{610}, O_{28}, F_{48}, P_{712}, T_{88}, F_{712}, T_{710}, F_{410}, F_{812}, P_{710}, FC_{612}, F_{412}, F_{814}, F_{816}, FC_{614}, F_{818}, T_{810}, O_{18}, P_{814}, F_{820}, O_{214}, T_{712}, O_{112}, F_{414}, F_{822}$ )	48.16	35	20.83
Difuso + GMDH	( $AF_{310}, F_{414}, FC_{618}, O_{212}, P_{712}, F_{416}$ )	<b>55.72</b>	6	3.57
<b>EmoEpoc Media</b>				
Ninguno		62.61	168.00	100.00
Estadístico + Orden		45.39	11.67	6.94
Estadístico + GMDH		49.37	3	1.79
Difuso + Orden		<b>56.16</b>	26	15.48
Difuso + GMDH		55.85	5.33	3.17

Tabla 4.21: Canales y frecuencias seleccionadas aplicando el criterio difuso + selección por orden. Se denotan como  $\odot$  aquellas características seleccionadas por un sujeto, como  $\oslash$  las seleccionadas por dos y como  $\otimes$  las seleccionadas por todos ellos. Datos EmoEpoc

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
AF3	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.	.
F7	$\oslash$	$\odot$	$\odot$	.	$\odot$	$\odot$	.	.	.	.	.	.
F3	.	.	.	.	.	.	.	.	.	.	.	.
FC5	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.	.
T7	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.
P7	$\odot$	$\oslash$	$\odot$	.	.	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$
O1	$\oslash$	$\odot$	$\oslash$	.	.	.	.	.	.	.	.	.
O2	$\odot$	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.	.	.
P8	$\oslash$	$\oslash$	$\oslash$	$\oslash$	.	.	.	.	.	.	.	.
T8	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.	.
FC6	$\odot$	$\odot$	$\odot$	$\odot$	.	.	$\odot$	.	.	$\odot$	$\odot$	$\odot$
F4	$\odot$	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.	.	.
F8	$\oslash$	$\oslash$	$\oslash$	$\oslash$	$\oslash$	$\oslash$	$\oslash$	$\oslash$	$\odot$	$\odot$	$\odot$	$\odot$
AF4	.	$\odot$	.	.	.	.	.	.	.	.	.	.
<b>Total</b>	16	16	12	7	3	4	4	3	2	3	3	3

muestra un mejor resultado que el conjunto inicial de 168 características para el Sujeto 3, utilizando una metodología basada en la aplicación del criterio difuso y GMDH. En este caso, el nivel de acierto alcanzado es mínimamente mayor que el original (de 55.29 % a 55.72 %) y el número de componentes seleccionadas se reduce a seis.

Esta combinación también proporciona los mejores resultados para el Sujeto 1, alcanzando un 67.78 %. Resulta curioso que se logra el mismo acierto utilizando también el método estadístico y la selección GMDH, si bien reduciendo a la mitad las características requeridas por el criterio difuso, por lo que entiende que ésta es una mejor opción. Respecto a componentes seleccionadas por todas las variantes de la metodología, sólo se encuentra el valor  $P8_{12}$  para este sujeto.

El criterio difuso con selección por orden ofrece el mejor acierto para el Sujeto 2, y la diferencia es tan abultada con respecto al resto de las variantes que condiciona los datos mostrados en la comparación general. Fundamentalmente, se eligen 22 componentes que consiguen un acierto del 64.21 %, nueve puntos por debajo del inicial, pero 10 mejor que la siguiente, que es de nuevo la combinación entre el método difuso y la selección GMDH.

Resulta también destacable que el método estadístico con selección por orden ofrece un menor rendimiento para todos los colaboradores, siendo alrededor de 20 puntos peor para el Sujeto 2 y 17 para el Sujeto 3. Además, se puede apreciar que el método estadístico selecciona, a excepción de la combinación con GMDH en el Sujeto 1, componentes menos significativas que el criterio difuso, quedando en todos los casos como las dos últimas aproximaciones en términos de rendimiento del sistema. Del mismo modo, la metodología formada por el criterio difuso y la selección por orden obtiene un número creciente de características a medida que el rendimiento de cada conjunto de datos del sistema disminuye, situándose entre 21 para el Sujeto 1 y 35 para el Sujeto 3.

Tabla 4.22: Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos capturados con Emotiv EPOC mostrados como %

Método de selección	Global	Motor	Derecha	Izquierda	Palabra
<b>EmoEpoc Sujeto 1</b>					
Todas características	69.04	82.22	41.61	72.63	92.00
Estadístico + Orden	63.39	80.96	25.50	75.42	86.67
Estadístico + GMDH	<b>67.78</b>	82.22	26.85	87.71	84.67
Difuso + Orden	66.11	82.85	30.87	79.89	84.67
Difuso + GMDH	<b>67.78</b>	79.50	45.64	68.16	89.33
<b>EmoEpoc Sujeto 2</b>					
Todas características	63.50	82.51	49.43	93.79	50.00
Estadístico + Orden	34.56	65.66	17.24	67.59	22.22
Estadístico + GMDH	41.25	68.68	18.39	74.48	35.42
Difuso + Orden	<b>54.21</b>	79.48	32.18	82.76	52.08
Difuso + GMDH	44.06	63.93	10.92	56.55	74.53
<b>EmoEpoc Sujeto 3</b>					
Todas características	55.29	80.35	47.40	53.10	66.90
Estadístico + Orden	38.23	59.83	36.42	29.66	48.97
Estadístico + GMDH	39.09	65.44	0.00	68.97	55.86
Difuso + Orden	48.16	66.32	55.49	20.00	67.59
Difuso + GMDH	<b>55.72</b>	79.70	53.18	49.28	66.21
<b>EmoEpoc Media</b>					
Todas características	62.61	81.69	46.15	73.17	69.63
Estadístico + Orden	45.39	68.82	26.39	57.56	52.62
Estadístico + GMDH	49.37	72.11	15.08	77.05	58.65
Difuso + Orden	<b>56.16</b>	76.22	39.51	60.88	68.11
Difuso + GMDH	55.85	74.38	36.58	57.66	76.69

En la Tabla 4.21 se puede apreciar que de las 76 características que se seleccionan en total para los tres sujetos, 51 se concentran en las bandas de frecuencias de 8, 10, 12 y 14Hz suponiendo el 67% del total. Llegados a este punto, merece la pena resaltar que los Sujetos 1 y 3 presentan la mayoría de sus componentes seleccionadas en parte inferior del espectro, mientras que para el Sujeto 2 las características se ubican en la parte alta:  $F7_{18}$  y  $F7_{20}$ , de  $P7_{18}$  hasta  $P7_{30}$ , de  $F8_{14}$  hasta  $F8_{30}$  o  $FC6_{20}$ ,  $FC6_{26}$ ,  $FC6_{28}$  y  $FC6_{30}$ . Además, no existe una sola componente común seleccionada para los tres usuarios.

Finalmente, se ha incluido en la Tabla 4.22 la distribución del acierto en la predicción de cada tarea: Izquierda -  $I$ , Derecha -  $D$  y Palabra -  $P$ . En este caso se puede apreciar que la precisión entre  $D$  e  $I$  mantiene una relación consistente entre los resultados con todas las componentes y aquéllos ofreciendo la mejor tasa de acierto para los Sujetos 1 y 3, incluso manteniendo los niveles de rendimiento alcanzados. Sin embargo, para el Sujeto 2 el criterio difuso con selección por orden, que alcanza el mejor resultado, presenta un valor global en torno a nueve puntos por debajo del original. Puesto que la capacidad de predecir  $P$  aumenta mínimamente, la bajada de rendimiento se acusa principalmente en la capacidad del mismo para predecir acertadamente las tareas motoras. En este contexto se puede apreciar un descenso en torno a 11 puntos en la capacidad de predecir  $I$ , y de 17 puntos en su capacidad de predecir  $D$ .



Atendiendo a los valores medios resulta patente que la tarea predicha con mayor dificultad es *D* para todas las combinaciones presentadas. Además, ésta es también la que logra un rendimiento más bajo para los Sujetos 1 y 2 tanto en sus valores de precisión iniciales como en los específicos de cada usuario. Del caso contrario son ejemplos las tareas *I* y *P*. La primera es la que se acierta con mayor precisión utilizando los métodos estadísticos mientras que la segunda es la predicha con mayor veracidad basando la metodología propuesta en la aplicación del criterio difuso. Se podría razonar que en los valores con todas las componentes los valores de acierto de *P* (69.63 %) y *D* (73.17 %) están sensiblemente más cerca que la diferencia entre cualquiera de ellos con *D*, que se sitúa en el 46.15 % de acierto medio para los tres usuarios.

#### 4.2.4. Datos capturados con Emotiv EasyCap - Posiciones BCI Competition

La tabla 4.23 muestra los valores obtenidos tras aplicar la metodología propuesta de selección de características a los datos EasyBCI. Al tomar las posiciones BCI, el número de componentes iniciales del vector de características se calcula como 8 canales por 12 frecuencias, lo que resulta en un total de 96 valores que evaluar.

Se puede apreciar como para el Sujeto 1, se reduce el número de características de 96 a cuatro y se consigue un aumento en el rendimiento de alrededor de tres puntos (78.45 %) utilizando una variante basada en el criterio difuso y la selección GMDH. De la misma forma, la combinación entre el método estadístico y la selección por orden genera un acierto en torno a tres cuartos de punto mayor que el alcanzado con todas las características. La combinación mostrando la menor precisión es la formada por el criterio difuso y la selección por orden, que rebaja en un 8.30 % el rendimiento del sistema hasta los 69.25 puntos.

Cabe destacar también que el método estadístico únicamente selecciona características en el canal C4, lo que permitiría a ese usuario controlar un dispositivo a partir de un sistema EEG con un único sensor y alcanzar un rendimiento en el control en torno al 75 %. De hecho, tomando como referencia la Figura 4.8 se pueden apreciar diferencias significativas en la concentración de potencia de señal para las tareas Izquierda - *I*, Derecha - *D* y Palabra - *P* en la banda de frecuencia entre 20 y 30Hz, lo que se traduce en la selección de características situadas en esta parte del espectro que muestra la Tabla 4.23. Para el criterio difuso la selección es bastante más diversa, incluyendo componentes de hasta siete de los ocho sensores para la selección por orden y de hasta tres para el modelo GMDH.

Para el Sujeto 2 es destacable que, al igual que para el Sujeto 1, la combinación ofreciendo el mayor nivel de precisión es la formada por el criterio difuso y selección GMDH. En este caso, el rendimiento se incrementa en un 2.87 % desde el 65.48 % al 67.36 % utilizando únicamente cinco características. No obstante, las aproximaciones basadas en el método estadístico muestran unos descensos en la precisión en torno al 15 % quedando el acierto, en el caso más desfavorable, en un 53.77 %.

El Sujeto 3 muestra una tendencia distinta en cuanto el proceso de selección de características y no se consigue encontrar combinación alguna que mejore la tasa de acierto inicial. En este caso, la mejor aproximación vuelve a ser la definida por la combinación del criterio difuso con selección por GMDH, descendiendo la precisión en un 2.51 %.

Tabla 4.23: Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos EasyBCI

Método de selección	Modelo	Tasa Acierto	No	%
<b>EasyBCI Sujeto 1</b>				
Ninguno	(...)	75.52	96	100.00
Estadístico + Orden	( $C_{422}, C_{424}, C_{428}, C_{426},$ $C_{420}, C_{430}, C_{410}$ )	76.15	7	7.29
Estadístico + GMDH	( $C_{420}, C_{426}, C_{410}, C_{428}, C_{424}$ )	74.88	5	5.21
Difuso + Orden	( $C_{48}, C_{38}, C_{310}, C_{410}, CP_{28},$ $CP_{210}, P_{310}, P_{38}, P_{312}, P_{314},$ $P_{z8}, C_{z8}, C_{312}, P_{z10}, P_{316},$ $C_{z10}, C_{412}, C_{420}, P_{48}, C_{422},$ $P_{412}, C_{416}, C_{418}$ )	69.25	23	23.96
Difuso + GMDH	( $CP_{210}, C_{428}, P_{z8}, CP_{212}$ )	<b>78.45</b>	4	4.17
<b>EasyBCI Sujeto 2</b>				
Ninguno	(...)	65.48	96	100.00
Estadístico + Orden	( $C_{312}, C_{310}, C_{314}, C_{330}, CP_{210},$ $C_{328}, CP_{212}, CP_{110}$ )	55.44	8	8.33
Estadístico + GMDH	( $C_{314}, C_{312}$ )	53.77	2	2.08
Difuso + Orden	( $C_{312}, C_{310}, C_{412}, C_{314}$ )	63.18	4	4.17
Difuso + GMDH	( $C_{314}, C_{420}, C_{z16}, C_{312}, CP_{210}$ )	<b>67.36</b>	5	5.21
<b>EasyBCI Sujeto 3</b>				
Ninguno	(...)	58.58	96	100.00
Estadístico + Orden	( $CP_{212}, CP_{214}, C_{38},$ $CP_{210}, C_{312}, C_{310}$ )	55.86	6	6.25
Estadístico + GMDH	( $CP_{212}, CP_{112}, C_{z8}$ )	51.05	3	3.13
Difuso + Orden	( $CP_{212}, CP_{210}, C_{312}, P_{312}, C_{310},$ $C_{412}, C_{z12}, P_{310}, C_{z10}, CP_{214},$ $P_{48}, C_{38}, C_{410}, CP_{28}, C_{z8},$ $C_{314}, CP_{112}, CP_{18}, P_{z8}, P_{410},$ $CP_{110}, C_{48}, C_{414}, CP_{114}, P_{38},$ $P_{z12}, P_{z14}, C_{z14}, P_{z16}, P_{z24},$ $P_{416}$ )	56.90	31	32.29
Difuso + GMDH	( $CP_{212}, CP_{18}, C_{48},$ $C_{z8}, CP_{114}, P_{414}$ )	<b>57.11</b>	6	6.25
<b>EasyBCI Media</b>				
Ninguno		66.53	96.00	100.00
Estadístico + Orden		62.48	7	7.29
Estadístico + GMDH		59.90	3.33	3.47
Difuso + Orden		63.11	19.33	20.14
Difuso + GMDH		<b>67.64</b>	5	5.21

Igualmente, los patrones en la capacidad de encontrar un conjunto reducido de características parecen ser consistentes entre los Sujetos 2 y 3. En ambos casos, no sólo la aproximación ofreciendo la mayor precisión concide sino que, ordenando los modelos de mayor a menor rendimiento, se define el mismo ranking: criterio difuso con selección GMDH, criterio difuso con selección por orden, método estadístico con selección por orden y método estadístico con selección GMDH. Los datos mostrados calculando la media de los valores de acierto de todos los usuarios confirman la misma tendencia ordenando las




Figura 4.8: EasyBCI Sujeto 1 - Distribución de potencia por tarea para la posición C4

diferentes metodologías expuestas de mayor a menor rendimiento.

Las variaciones de la precisión entre las diferentes variantes de la metodología aplicada se sitúan entre los seis puntos de puntos de diferencia para el Sujeto 3 y los 12 del Sujeto 2, pasando por los nueve del Sujeto 1.

Atendiendo a la concentración espectral de las características seleccionadas, se puede apreciar una mayor densidad de las mismas en la parte baja del espectro (Tabla 4.24). Siguiendo razonamientos anteriores, las componentes entre la banda de 8 y la de 14Hz suman el 80 % de las componentes escogidas. Igualmente, el conjunto de las mismas que permanecen en para cada sujeto presenta diferencias importantes por lo que, una vez más, no es posible generalizar un conjunto de características comunes a todos los usuarios de la muestra.

Por último, el análisis de la distribución de los aciertos entre las diferentes tareas (Izquierda - *I*, Derecha - *D* y Palabra - *P*) muestra de nuevo la tendencia de los resultados a mantener o mejorar la precisión en la predicción de *P* y Motor - *M*. No obstante, cuando se analizan éstos con detalle, el comportamiento de las tareas motoras individuales *I* y *D* presenta diferencias significativas entre los colaboradores de la muestra. Por una parte, para el Sujeto 1 tanto el rendimiento para predecir *I* como el mostrado prediciendo *D* mejora. Para el Sujeto 2, la mejora para la tarea *I* es más amplia que el descenso en el rendimiento prediciendo *D* pero ambos se mantienen en los rangos de la otra tarea motora utilizando el conjunto completo de componentes. Sin embargo, para el Sujeto 3 la diferencia entre el acierto prediciendo *I* y *D* se amplía desde los 14.14 puntos hasta los 48.80, puesto que si bien la capacidad de predecir derecha aumenta hasta el 74.50 %, la de predecir izquierda decrece hasta el 25.70 %, lo que fundamentalmente viene a significar

Tabla 4.24: Canales y frecuencias seleccionadas aplicando el criterio difuso + GMDH. Se denotan como  $\odot$  aquéllas características seleccionadas por un sujeto, como  $\oslash$  las seleccionadas por dos y como  $\otimes$  las seleccionadas por todos ellos. Datos EasyBCI

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
C3	.	.	$\odot$	$\odot$	.	.	.	.	.	.	.	.
Cz	$\odot$	.	.	.	$\odot$	.	.	.	.	.	.	.
C4	$\odot$	.	.	.	.	.	$\odot$	.	.	.	$\odot$	.
CP1	$\odot$	.	.	$\odot$	.	.	.	.	.	.	.	.
CP2	.	$\oslash$	$\oslash$	.	.	.	.	.	.	.	.	.
P3	.	.	.	.	.	.	.	.	.	.	.	.
Pz	$\odot$	.	.	.	.	.	.	.	.	.	.	.
P4	.	.	.	$\odot$	.	.	.	.	.	.	.	.
<b>Total</b>	4	2	3	3	1	.	1	.	.	.	1	.

Tabla 4.25: Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los capturados Emotiv EasyCap en las posiciones de los datos preprocesados del BCI Competition mostrados como %

Método de selección	Global	Motor	Derecha	Izquierda	Palabra
<b>EasyBCI Sujeto 1</b>					
Todas características	75.52	91.42	67.11	71.51	88.67
Estadístico + Orden	76.15	86.61	69.80	77.09	81.33
Estadístico + GMDH	74.88	87.45	75.84	69.27	79.33
Difuso + Orden	69.25	87.24	47.65	72.07	87.33
Difuso + GMDH	<b>78.45</b>	89.33	72.48	74.86	88.67
<b>EasyBCI Sujeto 2</b>					
Todas características	65.48	80.13	60.40	49.16	90.00
Estadístico + Orden	55.44	79.92	0.67	71.51	90.67
Estadístico + GMDH	53.77	80.54	1.34	65.36	92.00
Difuso + Orden	63.18	82.01	32.89	63.13	93.33
Difuso + GMDH	<b>67.36</b>	80.75	47.65	64.25	90.67
<b>EasyBCI Sujeto 3</b>					
Todas características	58.58	82.01	45.64	59.78	70.00
Estadístico + Orden	55.86	81.17	0.67	90.50	69.33
Estadístico + GMDH	51.05	77.82	79.87	0.56	82.67
Difuso + Orden	56.90	79.29	65.10	37.99	71.33
Difuso + GMDH	<b>57.11</b>	81.80	74.50	25.70	77.33
<b>EasyBCI Media</b>					
Todas características	66.53	84.52	57.72	60.15	82.89
Estadístico + Orden	62.48	82.17	23.71	79.70	80.44
Estadístico + GMDH	59.90	81.94	52.35	45.06	84.67
Difuso + Orden	63.11	82.85	48.55	57.73	84.00
Difuso + GMDH	<b>67.64</b>	83.96	64.88	54.94	85.56

que el clasificador predice dos estados mayoritariamente para este usuario:  $D$  y  $P$  (ver Anexo M).

De la misma forma, resulta significativa la existencia de algunas combinaciones para las que se puede apreciar claramente la tendencia anterior a predecir únicamente una de las tareas motoras. Entre éstas destacan los métodos estadísticos para los Sujetos 2 y 3, que alcanzan niveles de acierto para una de las tareas motoras en el rango entre el 0.56 % y el 1.34 %.

Otra conclusión importante que se puede extraer es la estabilidad en la capacidad de los subconjuntos de componentes para realizar la predicción de  $P$ , cuyo rango de variación se mantiene en torno a cinco puntos y resulta siempre la tarea mejor predicha para todas las variantes de la metodología. Igualmente, se aprecian diferencias poco significativas entre las capacidades medias iniciales del sistema para predecir  $D$  e  $I$  (57.75 % y 60.15 % respectivamente), lo que se traduce en que las variantes con selección por orden ofrecen una mayor precisión en la predicción de  $I$  mientras que las variantes con selección GMDH lo hacen con  $D$ .

#### 4.2.5. Datos capturados con Emotiv EasyCap - Posiciones Emotiv

Al igual que en los conjuntos anteriores, se encuentra un subconjunto de características que permite mejorar el rendimiento del sistema para los Sujetos 1 y 3. En ambos casos, la combinación ofreciendo el mejor resultado es la compuesta por el criterio difuso y la selección GMDH, que también presenta los valores más altos en términos generales.

Para el Sujeto 1 se sobrepasa el 56.07 % de acierto inicial utilizando únicamente cuatro características, mostrando una precisión del 58.58 %. Igualmente, la variante utilizando la selección por orden logra un acierto del 58.37 % utilizando cinco componentes. Es relevante que las características seleccionadas por una y otra combinación difieren por completo a pesar de encontrarse en sensores de la parte derecha del cerebro. En el caso de la selección GMDH todas las componentes pertenecen a posiciones distintas, por lo que en realidad la reducción conseguida tendría más impacto en el procesamiento que en la potencial fabricación de un sistema EEG. Sin embargo, para la selección por orden únicamente se seleccionan componentes en dos posiciones, la F8 (cuatro bandas de frecuencia) y la AF4 (banda de 8Hz). También es remarcable que para este usuario la suma del número de componentes seleccionadas por las cuatro aproximaciones es el más bajo.

El Sujeto 2 muestra la mayor disminución en el rendimiento de la sesión de prueba. En este caso, la mejor variante es la combinación entre el método estadístico y la selección por GMDH, que proporciona un valor del 48.12 % (bajando desde el 54.81 %), lo que supone un descenso en torno al 10 %. El resto de las combinaciones se mantiene muy cerca de ésta, con una diferencia máxima en torno a los dos puntos, si bien en los casos donde la selección se realiza por orden, con un número de características entre seis y diez veces mayor.

Como ya se ha enunciado anteriormente, las componentes seleccionadas para el Sujeto 3 también logran una mejor capacidad de acierto que la del escenario inicial. Para éste sí que se encuentran diferencias significativas entre la aproximación ganadora y el resto, especialmente en aquéllas basadas en el método estadístico, que presentan capacidades de acierto entre 14 y 17 puntos más bajas (33.47 % y 30.13 % respectivamente).

En términos generales la precisión media conseguida por la combinación entre el criterio

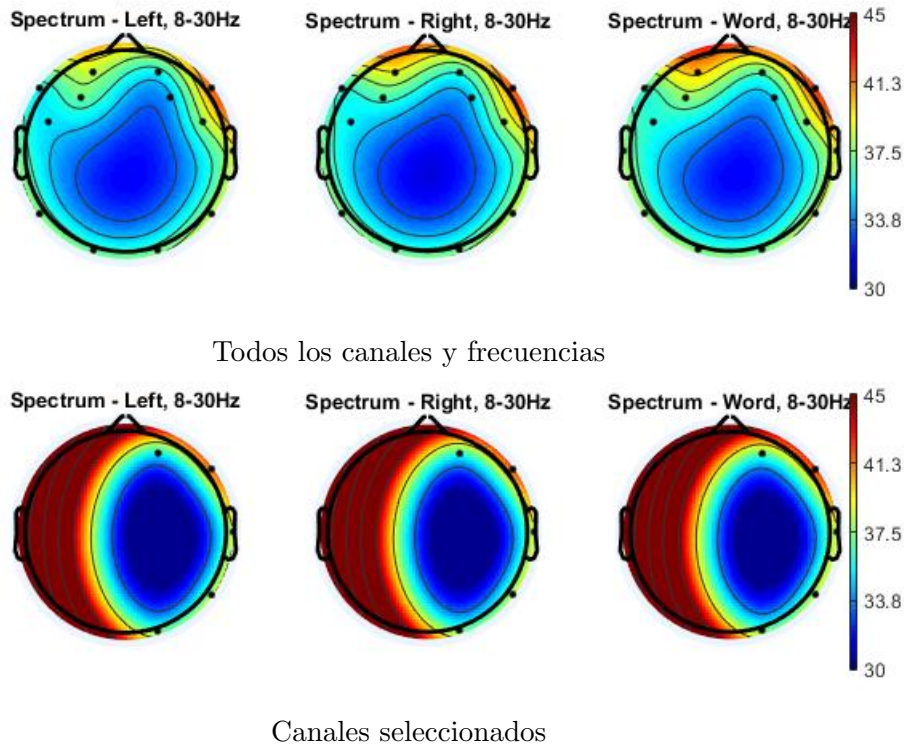


Figura 4.9: BCIEpoc Sujeto 1 - Comparativa de la distribución espectral de potencia en función de los canales seleccionados

difuso y la selección GMDH permite alcanzar el mejor resultado utilizando únicamente 4 características. A poca distancia queda el criterio difuso con selección por orden, aunque seleccionando un número de componentes sensiblemente mayor (en media por encima de 20 características más que la mejor aproximación). Finalmente se sitúan las variantes basadas en el método estadístico, penalizadas por el comportamiento mostrado para el Sujeto 3.

Al revisar los datos incluidos la Tabla 4.27 no se puede generalizar que la distribución frecuencial se ubique tan claramente en parte baja del espectro dado que, si bien para la banda de 8Hz se seleccionan cuatro características, en el espectro entre 8 y 14Hz sólo se añaden dos más, llegando a un total de seis (54.54%). Así mismo, también quedan cuatro componentes entre 26 y 30Hz y otras dos en las bandas de 18 y 20Hz. Si se analizan los datos usuario a usuario, se puede apreciar que para todos se eligen características en las bandas altas y bajas.

Por ejemplo, para el Sujeto 1, se seleccionan tanto la banda de 8Hz para las posiciones O2 y P8, como las de 28 y 30 Hz para los sensores F8 y T8 respectivamente. Dicho patrón se repite para el Sujeto 2, para el que la metodología propuesta mantiene las bandas de 8Hz para los sensores F8 y AF4 y 10Hz para el F7, si bien también elige las posiciones  $T8_{26}$  y  $F8_{28}$ . El Sujeto 3 muestra un comportamiento intermedio, donde las bandas seleccionadas están entre 14 y 22Hz con las características  $P7_{14}$ ,  $P8_{18}$  y  $P8_{22}$ .

Tabla 4.26: Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos EasyEpoc

Método de selección	Modelo	Tasa Acierto	No	%
<b>EasyEpoc Sujeto 1</b>				
Ninguno	(...)	56.07	168	100.00
Estadístico + Orden	( $O1_8, O1_{10}, O1_{12}, P8_{30}, P8_{28}, O1_{14}, P8_{26}, F8_{10}, O1_{26}, P8_{24}, T7_{24}, O1_{20}, O1_{22}$ )	52.30	13	7.74
Estadístico + GMDH	( $F8_8, P8_{30}, P8_{28}, P8_{26}, O1_{26}$ )	52.72	5	2.98
Difuso + Orden	( $F8_{30}, F8_{28}, F8_{26}, AF4_8, F8_8,$	58.37	5	2.98
Difuso + GMDH	( $P8_8, F8_{28}, O2_8, T8_{30}$ )	<b>58.58</b>	4	2.38
<b>EasyEpoc Sujeto 2</b>				
Ninguno	(...)	<b>54.81</b>	168	100.00
Estadístico + Orden	( $FC5_{30}, F7_{14}, FC5_{26}, FC5_{28}, P7_8, F7_{12}, FC5_{24}, P7_{10}, F7_{16}, T7_{12}, F7_{18}, FC5_{10}, F4_{22}, FC5_{22}, F8_8, F7_{24}, P7_{12}$ )	47.07	17	10.12
Estadístico + GMDH	( $P7_8, T7_{12}, F7_{16}$ )	<b>48.12</b>	3	1.79
Difuso + Orden	( $AF3_8, AF4_8, T8_{28}, T8_{26}, T8_{30}, F7_8, P7_8, O1_8, P8_8, O2_8, T8_{24}, F8_8, AF3_{10}, T7_8, T8_{22}, AF4_{10}, T7_{24}, FC6_{26}, T7_{26}, T7_{28}, T7_{30}, T8_8, F7_{10}, T7_{22}, FC6_{24}, T7_{14}, FC6_{28}, T7_{20}, T7_{12}$ )	47.49	29	17.26
Difuso + GMDH	( $T8_{26}, AF4_8, F8_8, F7_{10}, F8_{28}$ )	46.03	5	2.98
<b>EasyEpoc Sujeto 3</b>				
Ninguno	(...)	47.07	168	100.00
Estadístico + Orden	( $FC5_8, FC5_{10}, F8_{30}, AF3_8, F8_{28}, P7_8, F8_{26}, AF4_8, AF3_{10}, FC5_{12}, F8_{18}$ )	30.13	11	6.55
Estadístico + GMDH	( $AF4_8, FC5_{12}$ )	33.47	2	1.19
Difuso + Orden	( $T8_{22}, T8_{20}, AF3_8, T8_{24}, AF3_{10}, FC5_8, T8_{18}, AF3_{12}, AF3_{14}, O2_8, P8_{16}, AF3_{16}, O1_8, P8_{14}, AF3_{18}, T8_{16}, F8_8, P8_{28}, AF3_{20}, T7_{16}, P8_{24}, P8_{26}, P8_{30}, T8_{14}, FC5_{10}, T8_{26}, F3_8, F8_{10}$ )	41.42	28	16.67
Difuso + GMDH	( $P8_{22}, P8_{18}, P7_{14}$ )	<b>47.28</b>	3	1.79
<b>EasyEpoc Media</b>				
Ninguno		52.65	168.00	100.00
Estadístico + Orden		43.17	13.67	8.14
Estadístico + GMDH		44.77	3.33	1.98
Difuso + Orden		49.09	20.67	12.30
Difuso + GMDH		<b>50.63</b>	4	2.38

Finalmente, la selección de características mejora fundamentalmente la capacidad del sistema de predecir Palabra -  $P$ , cuya precisión aumenta para todos los usuarios. Sin embargo, no se puede decir lo mismo en cuando a su rendimiento prediciendo las tareas motoras Izquierda -  $I$  y Derecha -  $D$ . Para el Sujeto 1, la diferencia entre la precisión

Tabla 4.27: Canales y frecuencias seleccionadas aplicando criterio difuso + GMDH. Se denotan como  $\odot$  aquéllas características seleccionadas por un sujeto, como  $\oslash$  las seleccionadas por dos y como  $\otimes$  las seleccionadas por todos ellos. Datos EasyEpoc

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
AF3	.	.	.	.	.	.	.	.	.	.	.	.
F7	.	.	.	.	.	.	.	.	.	.	.	.
F3	.	$\odot$	.	.	.	.	.	.	.	.	.	.
FC5	.	.	.	.	.	.	.	.	.	.	.	.
T7	.	.	.	.	.	.	.	.	.	.	.	.
P7	.	.	.	$\odot$	.	.	.	.	.	.	.	.
O1	.	.	.	.	.	.	.	.	.	.	.	.
O2	$\odot$	.	.	.	.	.	.	.	.	.	.	.
P8	$\odot$	.	.	.	.	$\odot$	.	$\odot$	.	.	.	.
T8	.	.	.	.	.	.	.	.	.	$\odot$	.	$\odot$
FC6	.	.	.	.	.	.	.	.	.	.	.	.
F4	.	.	.	.	.	.	.	.	.	.	.	.
F8	$\odot$	.	.	.	.	.	.	.	.	.	$\oslash$	.
AF4	$\odot$	.	.	.	.	.	.	.	.	.	.	.
<b>Total</b>	4	1	.	1	.	1	.	1	.	1	2	1

prediciendo  $I$  y  $D$  disminuye para la combinación ganadora (criterio difuso combinado con GMDH), aunque ésta es inicialmente tan amplia que no es posible equilibrar la capacidad del sistema en la predicción de ambas tareas para ninguna de las variantes. La diferencia queda en torno a 20 puntos para el Sujeto 2, si bien la combinación ganadora aumenta la misma al reducir drásticamente su capacidad de predecir derecha (métodos estadístico + GMDH). La selección por los criterios difusos prácticamente iguala la capacidad de predecir ambas, dejando dichos valores entre el 50 % y 60 % de acierto. Así mismo, se encuentra un patrón similar para el Sujeto 3, para el cual las elecciones realizadas utilizando el método estadístico minimizan el acierto de una de las tareas motoras en beneficio de la otra, mientras que para el criterio difuso estas diferencias se equilibran, siendo la menor de ellas la mostrada por la variante formada por el criterio difuso y la selección GMDH.

Teniendo en cuenta los resultados promediados que aparecen en la parte inferior de la Tabla 4.28, se encuentra que globalmente la diferencia de acierto entre  $P$  e  $I$  está en torno a tres puntos, prácticamente triplicando a su vez el valor  $D$ . No obstante, resulta curioso que para las componentes elegidas el valor medio inicial de  $I$  desciende y el  $D$  asciende. Además, resulta destacable que el rendimiento prediciendo  $D$  mejora en tres de las cuatro opciones, llegando a aumentar alrededor de 18 puntos para el método estadístico con selección por orden en el mejor de los casos. El caso opuesto ocurre con  $I$ , cuya capacidad de identificación desciende muy sensiblemente desde el 64.43 % hasta el 38.36 % en el peor de los casos (método estadístico y selección por orden), siendo el 55.31 % del criterio difuso con selección GMDH el mejor valor representando aún una bajada en torno a nueve puntos.



Tabla 4.28: Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos capturados con Emotiv EasyCap en las posiciones estándar Emotiv EPOC mostrados como %

Método de selección	Global	Motor	Derecha	Izquierda	Palabra
<b>EasyEpoc Sujeto 1</b>					
Todas características	56.07	86.47	15.44	93.30	52.00
Estadístico + Orden	52.30	84.10	34.90	62.57	57.33
Estadístico + GMDH	52.72	84.52	16.78	67.60	70.67
Difuso + Orden	58.37	85.15	24.83	88.53	55.33
Difuso + GMDH	<b>58.58</b>	86.61	18.12	86.59	65.33
<b>EasyEpoc Sujeto 2</b>					
Todas características	54.81	72.59	38.26	58.66	66.67
Estadístico + Orden	47.07	64.44	16.78	49.16	74.67
Estadístico + GMDH	<b>48.12</b>	66.95	4.03	62.57	74.67
Difuso + Orden	47.49	71.76	59.06	51.96	30.67
Difuso + GMDH	46.03	69.04	59.06	54.75	22.67
<b>EasyEpoc Sujeto 3</b>					
Todas características	47.07	57.53	18.12	41.34	82.67
Estadístico + Orden	30.13	67.78	71.81	3.35	20.67
Estadístico + GMDH	33.47	45.40	21.54	2.79	72.00
Difuso + Orden	41.42	61.30	27.52	10.06	92.67
Difuso + GMDH	<b>47.28</b>	67.15	30.20	24.58	91.33
<b>EasyEpoc Media</b>					
Todas características	52.65	72.20	23.94	64.43	67.11
Estadístico + Orden	43.17	72.11	41.16	38.36	50.89
Estadístico + GMDH	44.77	65.52	17.45	44.32	72.45
Difuso + Orden	49.09	72.74	37.14	50.18	59.56
Difuso + GMDH	<b>50.67</b>	74.27	35.79	55.31	59.78

#### 4.2.6. Datos capturados con Emotiv EPOC - Base de datos extendida

Esta sección provee una visión más general de los resultados obtenidos aplicando cada una de las combinaciones propuestas de selección de características, dado que es la primera en la que se comparan resultados obtenidos para un número de usuarios relativamente alto.

En primer lugar, es destacable que la variante de la metodología basada en el método estadístico y la selección por orden es la que ofrece un peor rendimiento tanto general como por usuario (Tabla 4.29). De hecho, no supera en ninguna ocasión la tasa de acierto inicial para ningún sujeto utilizando el total de 168 características. En cuanto al número de componentes seleccionadas, se obtienen entre dos y 18, por lo que no se puede establecer ninguna generalización sobre este aspecto.

Por otra parte, tampoco se encuentra patrón alguno relacionando el descenso en el rendimiento global del sistema y el calculado para el subconjunto seleccionado. Tomando como ejemplo el Sujeto 5, esta aproximación sólo consigue un 37.66 % para las dos características elegidas mientras que para el total se alcanza un 60.67 %. Sin embargo, para el Sujeto 9 las componentes seleccionadas rinden un 51.46 %, en comparación con un 52.72 % del modelo con 168 características.

Los resultados mostrados en la Tabla 4.30 proporcionan un acierto medio del 43.67 %

Tabla 4.29: Conjuntos de características seleccionados para el método estadístico y selección por orden. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt

Sujeto	Características Seleccionadas	Tasa			Acierto Max
		Acierto	No	%	
1	( <i>AF3<sub>16</sub></i> , <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>F7<sub>12</sub></i> , <i>FC5<sub>8</sub></i> , <i>FC5<sub>10</sub></i> , <i>FC5<sub>12</sub></i> , <i>FC5<sub>14</sub></i> , <i>FC5<sub>16</sub></i> , <i>T7<sub>8</sub></i> , <i>FC6<sub>8</sub></i> )	59.83	11	6.55	67.57
2	( <i>FC5<sub>28</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>10</sub></i> , <i>P8<sub>12</sub></i> , <i>P8<sub>14</sub></i> , <i>F8<sub>8</sub></i> , <i>F8<sub>20</sub></i> , <i>F8<sub>22</sub></i> , <i>F8<sub>24</sub></i> )	60.88	11	6.55	62.97
3	( <i>AF3<sub>8</sub></i> , <i>T7<sub>8</sub></i> )	43.51	2	1.19	62.55
4	( <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>F7<sub>12</sub></i> , <i>F7<sub>14</sub></i> , <i>F7<sub>16</sub></i> , <i>F7<sub>18</sub></i> )	49.58	6	3.57	61.09
5	( <i>FC5<sub>22</sub></i> , <i>O1<sub>18</sub></i> )	37.66	2	1.19	60.67
6	( <i>T7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>T7<sub>16</sub></i> , <i>T7<sub>18</sub></i> , <i>T7<sub>20</sub></i> , <i>FC6<sub>8</sub></i> , <i>FC6<sub>10</sub></i> , <i>FC6<sub>12</sub></i> , <i>FC6<sub>14</sub></i> , <i>FC6<sub>30</sub></i> , <i>F8<sub>8</sub></i> , <i>F8<sub>10</sub></i> , <i>F8<sub>12</sub></i> , <i>F8<sub>14</sub></i> , <i>F8<sub>16</sub></i> )	32.22	15	8.93	57.95
7	( <i>AF3<sub>8</sub></i> , <i>AF3<sub>10</sub></i> , <i>AF3<sub>12</sub></i> , <i>AF3<sub>14</sub></i> , <i>AF3<sub>20</sub></i> , <i>F7<sub>20</sub></i> , <i>F3<sub>8</sub></i> , <i>F3<sub>10</sub></i> , <i>F3<sub>12</sub></i> , <i>FC5<sub>8</sub></i> , <i>FC5<sub>20</sub></i> , <i>P7<sub>8</sub></i> , <i>FC6<sub>8</sub></i> , <i>AF4<sub>8</sub></i> , <i>AF4<sub>10</sub></i> )	39.96	15	8.93	55.02
8	( <i>AF3<sub>30</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>T8<sub>8</sub></i> )	33.26	4	2.38	53.56
9	( <i>F7<sub>28</sub></i> , <i>F7<sub>30</sub></i> , <i>F4<sub>8</sub></i> , <i>F4<sub>10</sub></i> , <i>AF4<sub>8</sub></i> , <i>AF4<sub>14</sub></i> )	51.46	6	3.57	52.72
10	( <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>F7<sub>12</sub></i> , <i>F7<sub>14</sub></i> , <i>F7<sub>16</sub></i> , <i>F7<sub>18</sub></i> , <i>FC5<sub>8</sub></i> , <i>FC5<sub>10</sub></i> )	37.03	8	4.76	51.67
11	( <i>F7<sub>14</sub></i> , <i>F7<sub>16</sub></i> , <i>F3<sub>8</sub></i> , <i>F3<sub>10</sub></i> , <i>F3<sub>12</sub></i> , <i>F3<sub>14</sub></i> , <i>F3<sub>16</sub></i> , <i>F3<sub>18</sub></i> , <i>T7<sub>26</sub></i> , <i>T7<sub>28</sub></i> , <i>T7<sub>30</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>10</sub></i> , <i>P8<sub>12</sub></i> , <i>P8<sub>14</sub></i> , <i>P8<sub>16</sub></i> , <i>P8<sub>18</sub></i> , <i>P8<sub>22</sub></i> , <i>T8<sub>8</sub></i> )	33.47	18	10.71	50.00
12	( <i>T7<sub>30</sub></i> , <i>P7<sub>28</sub></i> , <i>P7<sub>30</sub></i> , <i>P8<sub>28</sub></i> , <i>P8<sub>30</sub></i> )	30.13	5	2.98	48.12
Media		42.42	8.58	5.11	56.99

Tabla 4.30: Conjuntos de características seleccionados para el método estadístico y selección GMDH. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt

Sujeto	Características Seleccionadas	Tasa			Acierto Max
		Acierto	No	%	
1	( <i>AF3<sub>16</sub></i> , <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>FC6<sub>8</sub></i> )	60.04	4	2.38	67.57
2	( <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>P8<sub>12</sub></i> )	<b>65.27</b>	3	1.79	62.97
3	( <i>AF3<sub>20</sub></i> , <i>FC6<sub>18</sub></i> )	39.75	2	1.19	62.55
4	( <i>F7<sub>12</sub></i> , <i>F3<sub>8</sub></i> )	48.12	2	1.19	61.09
5	( <i>FC5<sub>26</sub></i> , <i>AF4<sub>10</sub></i> , <i>AF4<sub>18</sub></i> )	36.82	3	1.79	60.67
6	( <i>FC6<sub>8</sub></i> , <i>F8<sub>14</sub></i> )	31.38	2	1.19	57.95
7	( <i>AF3<sub>20</sub></i> , <i>FC5<sub>20</sub></i> , <i>FC6<sub>8</sub></i> )	44.14	3	1.79	55.02
8	( <i>T8<sub>14</sub></i> )	31.38	1	0.60	53.56
9	( <i>F4<sub>8</sub></i> , <i>AF4<sub>8</sub></i> )	50.21	2	1.19	52.72
10	( <i>F7<sub>8</sub></i> , <i>F7<sub>14</sub></i> , <i>F7<sub>18</sub></i> )	36.82	3	1.79	51.67
11	( <i>P8<sub>12</sub></i> , <i>P8<sub>22</sub></i> )	38.70	2	1.19	50.00
12	( <i>P7<sub>28</sub></i> , <i>P8<sub>26</sub></i> )	<b>41.42</b>	2	1.19	48.12
Media		43.67	2.42	1.44	56.99

Tabla 4.31: Conjuntos de características seleccionados para el criterio difuso y selección por orden. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt

Sujeto	Características Seleccionadas	Tasa Acierto	No	%	Acierto Max
1	( <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>FC5<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>O1<sub>8</sub></i> , <i>O1<sub>10</sub></i> , <i>O1<sub>12</sub></i> , <i>O1<sub>14</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>12</sub></i> , <i>T8<sub>8</sub></i> , <i>T8<sub>18</sub></i> , <i>T8<sub>20</sub></i> , <i>T8<sub>22</sub></i> , <i>T8<sub>24</sub></i> , <i>T8<sub>26</sub></i> , <i>FC6<sub>8</sub></i> , <i>FC6<sub>10</sub></i> , <i>F4<sub>8</sub></i> , <i>F8<sub>8</sub></i> )	63.81	22	10.30	67.57
2	( <i>AF3<sub>8</sub></i> , <i>F7<sub>8</sub></i> , <i>FC5<sub>8</sub></i> , <i>T7<sub>8</sub></i> , <i>T7<sub>14</sub></i> , <i>P7<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>O1<sub>8</sub></i> , <i>O1<sub>10</sub></i> , <i>O1<sub>12</sub></i> , <i>O2<sub>8</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>10</sub></i> , <i>P8<sub>12</sub></i> , <i>T8<sub>8</sub></i> , <i>T8<sub>10</sub></i> , <i>F8<sub>8</sub></i> , <i>F8<sub>10</sub></i> , <i>F8<sub>12</sub></i> , <i>F8<sub>14</sub></i> , <i>F8<sub>16</sub></i> , <i>AF4<sub>8</sub></i> )	57.11	22	13.10	62.97
3	( <i>AF3<sub>8</sub></i> , <i>AF3<sub>10</sub></i> , <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>F7<sub>12</sub></i> , <i>F3<sub>8</sub></i> , <i>F3<sub>10</sub></i> , <i>F3<sub>12</sub></i> , <i>FC5<sub>8</sub></i> , <i>T7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>P7<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>O1<sub>8</sub></i> , <i>O1<sub>12</sub></i> , <i>O2<sub>8</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>10</sub></i> , <i>P8<sub>12</sub></i> , <i>T8<sub>8</sub></i> , <i>T8<sub>24</sub></i> , <i>T8<sub>26</sub></i> , <i>T8<sub>28</sub></i> , <i>T8<sub>30</sub></i> , <i>F4<sub>8</sub></i> , <i>F4<sub>10</sub></i> , <i>F4<sub>12</sub></i> , <i>F8<sub>8</sub></i> , <i>AF4<sub>8</sub></i> , <i>AF4<sub>10</sub></i> )	55.86	30	17.86	62.55
4	( <i>AF3<sub>8</sub></i> , <i>AF3<sub>10</sub></i> , <i>AF3<sub>24</sub></i> , <i>AF3<sub>26</sub></i> , <i>AF3<sub>28</sub></i> , <i>AF3<sub>30</sub></i> , <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>FC5<sub>8</sub></i> , <i>T7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>T7<sub>12</sub></i> , <i>T7<sub>14</sub></i> , <i>T7<sub>16</sub></i> , <i>T7<sub>30</sub></i> , <i>O2<sub>8</sub></i> , <i>T8<sub>8</sub></i> , <i>FC6<sub>8</sub></i> , <i>F4<sub>8</sub></i> , <i>F8<sub>8</sub></i> , <i>AF4<sub>8</sub></i> )	<b>50.00</b>	20	11.90	61.09
5	( <i>FC5<sub>24</sub></i> , <i>O1<sub>20</sub></i> )	<b>61.51</b>	2	1.19	60.67
6	( <i>AF3<sub>8</sub></i> , <i>AF3<sub>10</sub></i> , <i>AF3<sub>12</sub></i> , <i>AF3<sub>14</sub></i> , <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>FC5<sub>8</sub></i> , <i>T7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>T7<sub>12</sub></i> , <i>T7<sub>14</sub></i> , <i>T7<sub>16</sub></i> , <i>P7<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>P7<sub>12</sub></i> , <i>P7<sub>14</sub></i> , <i>P7<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>P7<sub>12</sub></i> , <i>P7<sub>14</sub></i> , <i>O1<sub>8</sub></i> , <i>O1<sub>10</sub></i> , <i>O1<sub>12</sub></i> , <i>O1<sub>14</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>O2<sub>12</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>10</sub></i> , <i>P8<sub>12</sub></i> , <i>P8<sub>14</sub></i> , <i>T8<sub>8</sub></i> , <i>T8<sub>10</sub></i> , <i>T8<sub>12</sub></i> , <i>T8<sub>30</sub></i> , <i>FC6<sub>8</sub></i> , <i>FC6<sub>10</sub></i> , <i>FC6<sub>12</sub></i> , <i>FC6<sub>14</sub></i> , <i>FC6<sub>16</sub></i> , <i>FC6<sub>18</sub></i> , <i>FC6<sub>20</sub></i> , <i>F4<sub>8</sub></i> , <i>F4<sub>10</sub></i> , <i>F4<sub>12</sub></i> , <i>F8<sub>8</sub></i> , <i>F8<sub>10</sub></i> , <i>F7<sub>18</sub></i> , <i>F7<sub>30</sub></i> , <i>FC5<sub>8</sub></i> , <i>FC5<sub>30</sub></i> , <i>T7<sub>22</sub></i> , <i>T7<sub>24</sub></i> , <i>T7<sub>26</sub></i> , <i>T7<sub>28</sub></i> , <i>T7<sub>30</sub></i> , <i>P7<sub>8</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>12</sub></i> , <i>P8<sub>14</sub></i> , <i>P8<sub>16</sub></i> , <i>P8<sub>18</sub></i> , <i>T8<sub>8</sub></i> , <i>T8<sub>10</sub></i> , <i>T8<sub>12</sub></i> , <i>T8<sub>16</sub></i> , <i>T8<sub>18</sub></i> , <i>T8<sub>26</sub></i> , <i>T8<sub>28</sub></i> , <i>T8<sub>30</sub></i> , <i>F8<sub>8</sub></i> , <i>AF4<sub>8</sub></i> )	54.39	43	25.60	57.95
7	( <i>F7<sub>18</sub></i> , <i>F7<sub>30</sub></i> , <i>FC5<sub>8</sub></i> , <i>FC5<sub>30</sub></i> , <i>T7<sub>22</sub></i> , <i>T7<sub>24</sub></i> , <i>T7<sub>26</sub></i> , <i>T7<sub>28</sub></i> , <i>T7<sub>30</sub></i> , <i>P7<sub>8</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>12</sub></i> , <i>P8<sub>14</sub></i> , <i>P8<sub>16</sub></i> , <i>P8<sub>18</sub></i> , <i>T8<sub>8</sub></i> , <i>T8<sub>10</sub></i> , <i>T8<sub>12</sub></i> , <i>T8<sub>16</sub></i> , <i>T8<sub>18</sub></i> , <i>T8<sub>26</sub></i> , <i>T8<sub>28</sub></i> , <i>T8<sub>30</sub></i> , <i>F8<sub>8</sub></i> , <i>AF4<sub>8</sub></i> )	<b>49.58</b>	28	16.67	55.02
8	( <i>AF3<sub>8</sub></i> , <i>AF3<sub>10</sub></i> , <i>AF3<sub>12</sub></i> , <i>AF3<sub>14</sub></i> , <i>AF3<sub>16</sub></i> , <i>AF3<sub>18</sub></i> , <i>AF3<sub>20</sub></i> , <i>AF3<sub>22</sub></i> , <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>F7<sub>12</sub></i> , <i>F3<sub>8</sub></i> , <i>FC5<sub>8</sub></i> , <i>T7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>O2<sub>12</sub></i> , <i>P8<sub>8</sub></i> , <i>T8<sub>8</sub></i> , <i>FC6<sub>8</sub></i> , <i>FC6<sub>10</sub></i> , <i>FC6<sub>12</sub></i> , <i>FC6<sub>18</sub></i> , <i>F4<sub>8</sub></i> , <i>F8<sub>8</sub></i> , <i>F8<sub>10</sub></i> , <i>F8<sub>12</sub></i> , <i>F8<sub>14</sub></i> , <i>F8<sub>16</sub></i> , <i>F8<sub>18</sub></i> , <i>AF4<sub>8</sub></i> , <i>AF4<sub>10</sub></i> , <i>AF4<sub>12</sub></i> , <i>AF4<sub>18</sub></i> , <i>AF4<sub>20</sub></i> , <i>AF4<sub>22</sub></i> , <i>AF4<sub>24</sub></i> , <i>AF4<sub>26</sub></i> , <i>AF4<sub>28</sub></i> , <i>AF4<sub>30</sub></i> )	37.87	41	24.40	53.56
9	( <i>F7<sub>8</sub></i> , <i>AF4<sub>8</sub></i> )	<b>58.37</b>	2	1.19	52.72
10	( <i>AF3<sub>8</sub></i> , <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>FC5<sub>8</sub></i> , <i>FC5<sub>10</sub></i> , <i>T7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>P7<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>P7<sub>12</sub></i> , <i>O1<sub>8</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>O2<sub>12</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>10</sub></i> , <i>P8<sub>12</sub></i> , <i>P8<sub>14</sub></i> , <i>P8<sub>30</sub></i> , <i>T8<sub>8</sub></i> , <i>T8<sub>10</sub></i> , <i>FC6<sub>8</sub></i> , <i>F4<sub>8</sub></i> , <i>F8<sub>8</sub></i> , <i>F8<sub>10</sub></i> )	43.10	25	14.88	51.67
11	( <i>F7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>T7<sub>12</sub></i> , <i>P7<sub>12</sub></i> , <i>O1<sub>10</sub></i> , <i>O1<sub>12</sub></i> , <i>O1<sub>14</sub></i> , <i>O1<sub>16</sub></i> , <i>O2<sub>10</sub></i> , <i>O2<sub>12</sub></i> , <i>O2<sub>14</sub></i> , <i>O2<sub>16</sub></i> , <i>P8<sub>8</sub></i> , <i>P8<sub>10</sub></i> , <i>T8<sub>10</sub></i> , <i>T8<sub>12</sub></i> , <i>F8<sub>8</sub></i> )	<b>49.79</b>	17	10.12	50.00
12	( <i>F7<sub>8</sub></i> , <i>F7<sub>10</sub></i> , <i>F3<sub>8</sub></i> , <i>FC5<sub>10</sub></i> , <i>FC5<sub>12</sub></i> , <i>T7<sub>8</sub></i> , <i>T7<sub>10</sub></i> , <i>T7<sub>12</sub></i> , <i>P7<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>O1<sub>8</sub></i> , <i>O1<sub>10</sub></i> , <i>O1<sub>12</sub></i> , <i>O1<sub>14</sub></i> , <i>O1<sub>18</sub></i> , <i>O2<sub>8</sub></i> , <i>O2<sub>10</sub></i> , <i>O2<sub>12</sub></i> , <i>P7<sub>8</sub></i> , <i>P7<sub>10</sub></i> , <i>P7<sub>12</sub></i> , <i>T8<sub>12</sub></i> , <i>F8<sub>8</sub></i> , <i>F8<sub>10</sub></i> )	38.91	24	14.29	48.12
<b>Media</b>		51.69	23	13.69	56.99

para todos los colaboradores, lo que es un valor algo mayor que el obtenido en la selección por orden (42.42 %). Además, se evidencia un descenso considerable en el número de

Tabla 4.32: Conjuntos de características seleccionados para el criterio difuso y selección por orden. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt

Sujeto	Características Seleccionadas	Tasa	No	%	Acierto
		Acierto			Max
1	( $F7_8, P7_8, O1_8, O1_{12}, O2_{12}, T8_8, T8_{24}, FC6_8$ )	<b>68.62</b>	8	4.76	67.57
2	( $T7_8, O2_8, P8_8, P8_{12}, T8_8, F4_8$ )	63.39	6	3.57	62.97
3	( $T8_{26}, F4_{12}$ )	<b>61.92</b>	2	1.19	62.55
4	( $AF3_{10}, F7_8, T7_{12}, T7_{30}, T8_{10}$ )	49.79	5	2.98	61.09
5	( $AF3_8, T8_{12}$ )	36.85	2	1.19	60.67
6	( $AF3_{12}, AF3_{14}, T7_8, T7_{10}, P7_{12}, P7_{14}, O2_8$ )	<b>54.81</b>	7	4.17	57.95
7	( $FC5_8, T7_{24}, T7_{26}, P8_{14}, P8_{16}, T8_{12}, T8_{28}$ )	43.93	7	4.17	55.02
8	( $FC6_{10}$ )	<b>39.75</b>	1	24.40	53.56
9	( $AF3_8, P8_8, F8_8$ )	54.39	3	1.79	52.72
10	( $O2_8, O2_{12}, P8_{10}$ )	<b>46.44</b>	3	1.79	51.67
11	( $O1_{16}, O2_{20}, F8_8$ )	46.03	3	1.79	50.00
12	( $FC5_8, T7_{12}, P7_8, O1_{14}$ )	33.68	4	2.38	48.12
<b>Media</b>		49.97	4.25	2.53	56.99

características elegidas, quedando definidos los conjuntos por entre uno y cuatro elementos. Asimismo, esta variante ofrece los mejores resultados de la metodología para dos de los sujetos, en concreto para el 2 y el 12, presentando en el primero de los casos un acierto mayor al del modelo inicial completo (62.97 %).

El análisis de la Tabla 4.31 revela que la combinación entre el criterio difuso y la selección por orden alcanza los mejores resultados en términos generales, con un acierto medio del 51.69 %. En concreto, esta aproximación resulta óptima para cinco de los colaboradores, mientras que para otros dos más logra resultados por encima de los calculados para el modelo completo de 168 componentes. En concreto, para los Sujetos 5 y 9 el acierto alcanzado supera al de los modelos completos únicamente tomando dos características (61.51 % y 58.37 % respectivamente). Excluyendo éstos, se puede apreciar que los conjuntos seleccionados incluyen un elevado número de componentes. De hecho, se forman grupos de entre 17 y 43 características, con una media por encima de 27 elementos, lo que conlleva un requisito de algo más de un 16 % de las componentes totales para producir una salida.

La Tabla 4.32 presenta un patrón ciertamente similar al anterior, si bien alcanzando un valor más bajo de acierto medio (49.97 %). Igualmente, el conjunto de características elegidas resulta en la mejor precisión posible para cinco de los colaboradores, superando el rendimiento del modelo total para tres de ellos. Además, si bien el acierto medio se sitúa casi dos puntos por debajo de la aproximación anterior utilizando el criterio difuso y la selección por orden, la cantidad de información requerida es sensiblemente menor. Concretamente, esta combinación elige entre una y ocho características (en media 4.25), mientras que en la variante anterior el rango está entre dos y 43 (en media 13.69). Es decir, dos puntos más de acierto medio tienen un coste de procesamiento tres veces superior. Esta relación se presenta de una forma más clara en la Figura 4.10, que muestra la relación




Figura 4.10: Número de características por cada punto de la tasa de acierto

entre la precisión global conseguida y número de características seleccionadas.

Atendiendo a pautas de eficiencia, crear conjuntos de componentes utilizando el criterio difuso y la selección por orden ofrece el mejor de los resultados con el mayor coste, mientras que el método estadístico con selección GMDH es la opción más efectiva. Cabe destacar que la combinación más económica sólo alcanza el 43.67 % de precisión media, por lo que podría ser más adecuado la utilización de la aproximación difusa con selección GMDH en una implementación real.

#### 1. Modelo común

Una vez obtenidos datos de una población suficiente de usuarios se evalúa la posibilidad de crear un modelo común para todos ellos. Para ello se buscan todas aquellas características seleccionadas por cada variante de la metodología y se relacionan con el número de usuarios para las que se eligieron.

La Figura 4.11 muestra la frecuencia de aparición de las componentes seleccionadas con respecto al número de usuarios. El primer punto del gráfico es el valor del número medio de características seleccionadas por cada combinación. Desde éste los valores primeramente ascienden para descender de nuevo al revisar para cuántos usuarios aparece cada determinada componente. Por ejemplo, analizando la metodología basada en la combinación entre el criterio difuso y la selección por orden se puede apreciar que existen 91 componentes elegidas para al menos uno de los colaboradores de la muestra. El valor desciende hasta 55 al evaluar aquellas presentadas para al menos dos usuarios y a 38 cuando se revisan las que se incluyeron para tres de ellos. Finalmente, sólo hay dos características que aparezcan para 11 de los sujetos y ninguna común a todos.

Cabe destacar que sólo hay componentes repetidas para cuatro o más sujetos para la metodología basada en el criterio difuso con selección por orden, siendo tres sujetos el máximo para el resto de variantes. Así, se incluyen las características  $F7_8$ ,  $F7_{10}$ ,  $F7_{12}$ ,  $F7_{14}$ ,  $F7_{16}$ ,  $FC5_8$ ,  $T7_8$  y  $FC6_8$  para el método estadístico con selección por




Figura 4.11: Características comunes en los modelos en función del número de sujetos para los que aparecen




Figura 4.12: Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios

orden,  $FC6_8$  para el método estadístico con selección por GMDH y  $T7_{12}$  y  $O2_8$  para el criterio difuso con selección por GMDH.

Resulta asimismo significativo revisar el impacto en el rendimiento para cada sujeto que hubiese alcanzado un sistema basado en la utilización de únicamente dichas componentes comunes. Para evaluar este punto se repite el proceso de clasificación tantas veces como usuarios de la muestra para cada conjunto de componentes comunes y se promedia el resultado para cada variante de la metodología de selección de características presentada (el detalle de los resultados se incluye en el Apéndice O). Gráficamente, el resultado para las primeras tres iteraciones se presenta en la Figura 4.12.

En resumen, aparece un incremento en el acierto inicial para las aproximaciones basadas en el método estadístico. Primeramente, para el caso de selección por orden se pasa de prácticamente nueve características en media a un modelo con 71 com-




Figura 4.13: Niveles de acierto alcanzados seleccionando conjuntos comunes de características utilizando una selección de características basada en el criterio difuso y una selección por orden

ponentes, lo que provee al sistema de mayor cantidad de información para calcular la salida. El caso es análogo a la selección por GMDH, que pasa de algo más de dos características hasta 24.

Los cálculos para el criterio difuso muestran un mantenimiento de la precisión entre la selección de características media y el resultado utilizando el primero de los grupos. No obstante, es remarcable que para la selección por orden se pasa originalmente de 23 características a 91 y que para GMDH el valor medio inicial está en algo más de cuatro componentes antes de alcanzar las 24 en la primera iteración.

A partir de ese punto, existe un claro descenso de la tasa de acierto relacionado con la disminución del tamaño del conjunto de características. De hecho, se puede señalar la existencia de una relación entre el acierto en la iteración  $\geq 3$  y el número de componentes disponible para cada modelo. Así, para el criterio difuso con selección por orden se realiza el cálculo utilizando 38 componentes, para el método estadístico con selección por orden se tratan ocho características, para el criterio difuso con selección GMDH se usan dos y únicamente una componente es utilizada para el método estadístico con selección por orden (Figura 4.11).

Revisando con más detalle la relación entre el número de características seleccionadas y el acierto alcanzado se encuentran resultados similares entre las variantes basadas en el criterio difuso. Concretamente, la combinación entre el criterio difuso y la selección GMDH muestra un descenso de la tasa de acierto al rango del 41 % para un conjunto de dos características, que es el número de las mismas común a tres sujetos. De igual modo, tal y como recoge la Figura 4.13, para el criterio difuso y la selección por orden sólo se llega a un nivel comparable de precisión cuando se utilizan componentes comunes a 10 o más usuarios, formando un nuevo subconjunto de tres componentes.

Para concluir este análisis, se revisa la distribución frecuencial de las características

Tabla 4.33: Canales y frecuencias seleccionadas aplicando el método estadístico + selección por orden para características comunes entre sujetos. Se denotan como  $\odot$  aquellas características seleccionadas para al menos un sujeto, como  $\oslash$  las seleccionadas por al menos dos y como  $\otimes$  las seleccionadas por al menos tres ellos. Datos EmoExt

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
AF3	$\oslash$	$\odot$	$\odot$	$\odot$	$\odot$	.	$\odot$	.	.	.	.	$\odot$
F7	$\otimes$	$\otimes$	$\otimes$	$\otimes$	$\otimes$	$\odot$	$\odot$	.	.	.	$\odot$	$\odot$
F3	$\oslash$	$\oslash$	$\odot$	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.
FC5	$\otimes$	$\oslash$	$\odot$	$\odot$	$\odot$	.	$\odot$	.	$\odot$	.	$\odot$	.
T7	$\otimes$	$\odot$	.	.	$\odot$	$\odot$	$\odot$	.	.	$\odot$	$\odot$	$\oslash$
P7	$\odot$	.	.	.	.	.	.	.	.	.	$\odot$	$\odot$
O1	.	.	.	.	.	$\odot$	.	.	.	.	.	.
O2	$\oslash$	$\oslash$	.	.	.	.	.	.	.	.	.	.
P8	$\oslash$	$\oslash$	$\oslash$	$\oslash$	$\odot$	.	.	$\odot$	.	.	$\odot$	$\odot$
T8	$\oslash$	.	.	.	.	.	.	.	.	.	.	.
FC6	$\otimes$	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.	.	$\odot$
F4	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.	.
F8	$\oslash$	$\odot$	$\odot$	$\odot$	$\odot$	.	$\odot$	$\odot$	$\odot$	.	.	.
AF4	$\oslash$	$\odot$	.	$\odot$	.	.	.	.	.	.	.	.
<b>Total</b>	28	17	11	11	9	4	5	2	2	1	5	7

comunes seleccionadas para todas las variantes de la metodología. Este análisis se recoge en las tablas 4.33, 4.34, 4.35 y 4.36. En todos los casos se puede observar que las componentes seleccionadas se concentran en la parte baja del espectro y que aquellas comunes a tres sujetos o más ( $\otimes$ ) tienden a agruparse aún más entre 8 y 14Hz.

De una forma más precisa, para el método estadístico y selección por orden hasta cuatro características de las ocho comunes para tres o más sujetos se encuentran en la banda de 8Hz. No obstante, también se distingue en la parte muy alta del espectro la aparición de otro clúster entre los 28 y los 30Hz. En resumen, en torno al 55 % de los valores seleccionados quedan ubicados en todos los casos entre 8 y 12Hz, dato que supera el 65 % incluyendo la banda de 14Hz.

La Tabla 4.34 presenta un comportamiento análogo para las características elegidas a partir del método estadístico y la selección GMDH. En esta ocasión la concentración en las frecuencias bajas es menos evidente y sólo reúne alrededor del 40 % de las componentes entre 8 y 12Hz, ascendiendo casi al 52 % al llegar hasta 14Hz. No obstante, es destacable que  $FC6_8$  es la única común a tres sujetos y que entre las repetidas para dos usuarios también se incluyen la  $F7_8$  y  $P8_{12}$ . De modo contrario al anterior, prácticamente no se encuentran componentes seleccionadas en la parte alta del espectro.

El ejemplo más obvio aparece para la combinación entre el criterio difuso y la selección por orden. En este caso se puede observar que prácticamente todas las frecuencias de las tres primeras columnas de la Tabla 4.35 son seleccionadas para tres



Tabla 4.34: Canales y frecuencias seleccionadas aplicando el método estadístico + selección GMDH para características comunes entre sujetos. Se denotan como  $\odot$  aquellas características seleccionadas para al menos un sujeto, como  $\oslash$  las seleccionadas por al menos dos y como  $\otimes$  las seleccionadas por al menos tres ellos. Datos EmoExt

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
AF3	.	.	.	.	$\odot$	.	$\oslash$	.	.	.	.	.
F7	$\oslash$	$\odot$	$\odot$	$\odot$	.	$\odot$	.	.	.	.	.	.
F3	$\odot$	.	.	.	.	.	.	.	.	.	.	.
FC5	.	.	.	.	.	.	$\odot$	.	.	$\odot$	.	.
T7	.	.	.	.	.	.	.	.	.	.	$\odot$	.
P7	.	.	.	.	.	.	.	.	.	.	.	.
O1	.	.	.	.	.	.	.	.	.	.	.	.
O2	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.	.
P8	.	.	$\oslash$	.	.	.	.	$\odot$	.	$\odot$	.	.
T8	.	.	.	$\odot$	.	.	.	.	.	.	.	.
FC6	$\otimes$	.	.	.	.	$\odot$	.	.	.	.	.	.
F4	$\odot$	.	.	.	.	.	.	.	.	.	.	.
F8	.	.	.	$\odot$	.	.	.	.	.	.	.	.
AF4	$\odot$	$\odot$	.	.	$\odot$	.	.	.	.	.	.	.
<b>Total</b>	9	3	3	3	2	2	3	1	.	2	1	.

Tabla 4.35: Canales y frecuencias seleccionadas aplicando el criterio difuso + selección por orden para características comunes entre sujetos. Se denotan como  $\odot$  aquellas características seleccionadas para al menos un sujeto, como  $\oslash$  las seleccionadas por al menos dos y como  $\otimes$  las seleccionadas por al menos tres ellos. Datos EmoExt

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
AF3	$\otimes$	$\otimes$	$\oslash$	$\oslash$	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$	.	$\odot$
F7	$\otimes$	$\otimes$	$\oslash$	.	.	$\odot$	.	.	.	.	.	$\odot$
F3	$\otimes$	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.
FC5	$\otimes$	$\otimes$	$\oslash$	.	.	.	.	.	.	.	.	$\odot$
T7	$\otimes$	$\otimes$	$\otimes$	$\otimes$	$\oslash$	.	.	$\oslash$	$\odot$	$\odot$	$\odot$	$\oslash$
P7	$\otimes$	$\otimes$	$\otimes$	$\odot$	.	.	.	.	.	.	.	.
O1	$\otimes$	$\otimes$	$\otimes$	$\otimes$	$\odot$	.	.	.	.	.	.	.
O2	$\otimes$	$\otimes$	$\otimes$	$\otimes$	$\odot$	.	.	.	.	.	.	.
P8	$\otimes$	$\otimes$	$\otimes$	$\otimes$	$\odot$	$\odot$	.	.	.	.	.	.
T8	$\otimes$	$\otimes$	$\otimes$	$\odot$	$\odot$	$\oslash$	$\odot$	$\odot$	$\oslash$	$\otimes$	$\otimes$	$\otimes$
FC6	$\otimes$	$\otimes$	$\oslash$	$\odot$	$\odot$	$\oslash$	$\odot$	.	.	.	.	.
F4	$\otimes$	$\oslash$	$\oslash$	.	.	.	.	.	.	.	.	.
F8	$\otimes$	$\otimes$	$\oslash$	$\oslash$	$\oslash$	$\odot$	.	.	.	.	.	.
AF4	$\otimes$	$\oslash$	$\odot$	.	.	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$	$\odot$
<b>Total</b>	42	38	32	19	10	9	4	5	5	6	5	9

o más sujetos. Además, se puede apreciar una tendencia decreciente a medida que se avanza a través del espectro de frecuencias, con una clara disminución desde 32 a 19

Tabla 4.36: Canales y frecuencias seleccionadas aplicando el criterio difuso + selección GMDH para características comunes entre sujetos. Se denotan como  $\odot$  aquéllas características seleccionadas para al menos un sujeto, como  $\oslash$  las seleccionadas por al menos dos y como  $\otimes$  las seleccionadas por al menos tres ellos. Datos EmoExt

Hz $\rightarrow$	8	10	12	14	16	18	20	22	24	26	28	30
AF3	$\oslash$	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.	.	.
F7	$\oslash$	.	.	.	.	.	.	.	.	.	.	.
F3	.	.	.	.	.	.	.	.	.	.	.	.
FC5	$\oslash$	.	.	.	.	.	.	.	.	.	.	.
T7	$\oslash$	.	$\otimes$	.	.	.	.	.	$\odot$	$\odot$	.	$\odot$
P7	$\oslash$	.	$\odot$	$\odot$	.	.	.	.	.	.	.	.
O1	$\odot$	.	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.	.
O2	$\otimes$	.	$\oslash$	.	.	.	$\odot$	.	.	.	.	.
P8	$\oslash$	$\odot$	$\odot$	$\odot$	$\odot$	.	.	.	.	.	.	.
T8	$\odot$	$\odot$	$\oslash$	.	.	.	.	.	$\odot$	$\odot$	$\odot$	.
FC6	$\odot$	$\odot$	.	.	.	.	.	.	.	.	.	.
F4	$\odot$	.	$\odot$	.	.	.	.	.	.	.	.	.
F8	$\oslash$	.	.	.	.	.	.	.	.	.	.	.
AF4	.	.	.	.	.	.	.	.	.	.	.	.
<b>Total</b>	21	4	12	4	2	.	1	.	2	2	1	1

componentes entre 12 y 14Hz. En resumen, se incluyen entre 8 y 12Hz algo más del 60 % de las características y, añadiendo la banda de 14Hz, la cifra supera el 71 %.

Finalmente, y al igual que en casos anteriores, la Tabla 4.36 muestra una concentración del total de las características comunes seleccionadas en los tres casos del 74 % entre 8 y 12Hz, con todas características compartidas por tres sujetos ( $T7_{12}$  y  $O2_8$ ) en esa banda de frecuencias.

### 4.3. Interpretabilidad de los resultados

#### 4.3.1. Modelo Unificado

La Tabla 4.14 muestra la existencia de número de componentes seleccionadas para todos los usuarios BCIComp. Por ejemplo, para el Sujeto 1 siempre se seleccionan las características  $C3_{10}$  y  $CP1_{10}$ , mientras que las componentes  $C3_{10}$  y  $C4_{10}$  siempre se eligen para el Sujeto 2 y  $C3_{12}$  y  $C3_{14}$  para el Sujeto 3. Estos resultados conducen a la elaboración de un modelo unificado para todos los usuarios BCIComp incluyendo las características  $C3_{10}$ ,  $C3_{12}$ ,  $C3_{14}$ ,  $C4_{10}$  y  $CP1_{10}$  cuyo rendimiento se recoge en la Tabla 4.37.

Como se puede observar la precisión es algo más baja que en los modelos específicos calculados para cada colaborador, limitándose a una reducción de entre el 3 y el 4 %. No obstante, este resultado continua siendo mejor que el alcanzado por el ganador del BCI Competition III set V, manteniendo las restricciones establecidas en las reglas del mismo.

Los índices de acierto del modelo completo son en general superiores a los del modelo reducido salvo en predecir Derecha -  $D$ , donde el modelo reducido presenta una mayor

Tabla 4.37: Comparación de la precisión alcanzada para los datos preprocesados BCI Competition III dataset V entre la metodología propuesta y las mejores propuestas de la literatura. Se incluye el modelo unificado. Se denotan con \* las aportaciones propias

Método de selección	Sujeto 1	Caract.	Sujeto 2	Caract.	Sujeto 3	Caract.	Media
Campeón BCI Competition ([133])	79.60	96	70.31	96	56.02	96	68.65
MDLA [166]	79.68	9	66.82	17	54.59	1	67.03
SVM y con filtros espaciales evolucionados + filtros de selección de frecuencias ([143])	78.14	32	71.33	16	59.07	40	69.58
Mapas EEG [146]	85.71	8	73.80	8	64.28	8	74.60
Estadístico + GMDH*	<b>87.64</b>	<b>3</b>	<b>81.57</b>	<b>3</b>	<b>59.40</b>	<b>3</b>	<b>76.20</b>
Difuso + GMDH*	<b>89.05</b>	<b>4</b>	<b>82.49</b>	<b>4</b>	<b>57.80</b>	<b>3</b>	<b>76.60</b>
Modelo Unificado*	83.56	5	78.34	5	56.42	5	72.77

Tabla 4.38: Niveles de precisión alcanzados por tarea para el modelo unificado en comparación con los niveles alcanzados para los datos preprocesados BCI Competition III dataset V mostrados como %

	Global	Motor	Derecha	Izquierda	Palabra
<b>BCIComp Sujeto 1</b>					
Todas características	87.67	92.47	78.91	92.31	90.56
Estadístico + Orden	85.39	90.64	85.16	73.85	93.89
Estadístico + GMDH	87.67	92.47	82.03	86.92	92.22
Difuso + Orden	<b>89.95</b>	92.69	90.63	92.31	87.78
Difuso + GMDH	89.50	92.92	90.63	86.92	90.56
Modelo Unificado	83.56	86.76	92.19	90.00	72.78
<b>BCIComp Sujeto 2</b>					
Todas características	82.26	88.02	81.25	77.78	85.71
Estadístico + Orden	81.80	86.64	82.64	83.33	80.22
Estadístico + GMDH	81.57	86.64	80.56	83.33	81.32
Difuso + Orden	81.80	86.64	82.64	83.33	80.22
Difuso + GMDH	<b>82.49</b>	87.10	88.19	87.04	75.27
Modelo Unificado	78.34	84.10	87.50	84.26	67.58
<b>BCIComp Sujeto 3</b>					
Todas características	58.72	75.23	73.97	24.00	80.00
Estadístico + Orden	57.57	80.05	81.51	24.00	68.57
Estadístico + GMDH	<b>59.40</b>	80.73	73.97	29.33	76.43
Difuso + Orden	52.52	78.44	73.29	19.33	66.43
Difuso + GMDH	57.80	81.42	69.18	25.33	80.71
Modelo Unificado	56.42	81.19	76.03	28.00	66.43

precisión para todos los sujetos. Teniendo en cuenta las características incluidas en el modelo unificado, se puede apreciar que las situadas en el hemisferio izquierdo del cerebro ( $C3_{10}$ ,  $C3_{12}$ ,  $C3_{14}$  y  $CP1_{10}$ ) acumulan el 80 % del total. Por tanto, partiendo de que el fenómeno de ERD es claramente perceptible en cuando se ejecutan o imaginan movimientos de miembros en el área opuesta del mismo, es razonable que predecir  $D$  sea la tarea detectada de un modo más preciso.

Por otra parte, estos mismos sensores (C3, CP1 y C4) se ubican en un área del cerebro eminentemente asociada a la detección de movimiento, por lo que es previsible un decremento en la capacidad del sistema para predecir Palabra -  $P$ .

#### 4.3.2. Reglas difusas

Una de las propiedades más relevantes de los sistemas difusos es su interpretabilidad en forma de conjunto de reglas que los acerca al lenguaje natural. Los modelos FasArt participan de esta propiedad y permiten la extracción de un conjunto de reglas de tipo IF ... THEN que describen su funcionamiento. Sin embargo, el entendimiento y la extracción de conclusiones al analizar las mismas de forma manual se torna dificultoso a medida que el número de éstas crece.

Tabla 4.39: Resultados de predicción de la sesión de test para cada uno de los módulos clasificadores individuales S-dFasArt del modelo unificado. (Notación:  $s_x s_y s_z$  = Sujeto:  $x$ , Sesión para aprendizaje:  $y$ , Sesión para el ajuste-poda:  $z$ ). Datos BCIComp

Módulo S-dFasArt	Reglas	Reglas Poda	Acierto
Sujeto 1			
$s_1 s_1 s_2$	118	64	82.93
$s_1 s_1 s_3$	118	32	80.94
$s_1 s_2 s_1$	127	43	83.50
$s_1 s_2 s_3$	127	61	84.59
$s_1 s_3 s_1$	136	31	75.20
$s_1 s_3 s_2$	136	42	<b>86.30</b>

En el apartado 4.2.1 se reduce la dimensionalidad del problema de 96 a 5 características, lo que no es suficiente cuando se tiene en cuenta que la arquitectura S-dFasArt propuesta se basa en el funcionamiento de seis módulos trabajando paralelamente (Figura 2.35). Por tanto, para buscar un subconjunto de reglas que representen los criterios de clasificación se realiza una aproximación en dos etapas.

En primer lugar se mide la precisión de cada uno de los módulos S-dFasArt utilizando la sesión de test de cada sujeto y se toma aquel mostrando el mayor rendimiento. En la Tabla 4.39 se recogen los resultados para los diferentes modelos que se generan. Se puede observar que el mecanismo de poda reduce considerablemente el número inicial de reglas generadas (Columnas: Reglas y Reglas Poda). No obstante, el número final sigue siendo elevado como para realizar un análisis manual de las mismas.

En una segunda etapa, se seleccionan tres reglas para el clasificador elegido anteriormente, cada una asociada a una tarea motora: Izquierda -  $I$ , Derecha -  $D$  y Palabra -  $P$ . El criterio para elegir una regla de entre todas las que se asocian a la misma etiqueta se basa en la contribución neta de la misma a la capacidad de acierto del sistema. Por tanto se calcula la diferencia entre las veces que siendo esta regla la más activada se produce un acierto y las ocasiones en las que su activación conduce a un error. Como resultado, se obtienen una serie de reglas difusas con una estructura como la siguiente para Derecha -  $D$ , Izquierda -  $I$  y Palabra -  $P$ .

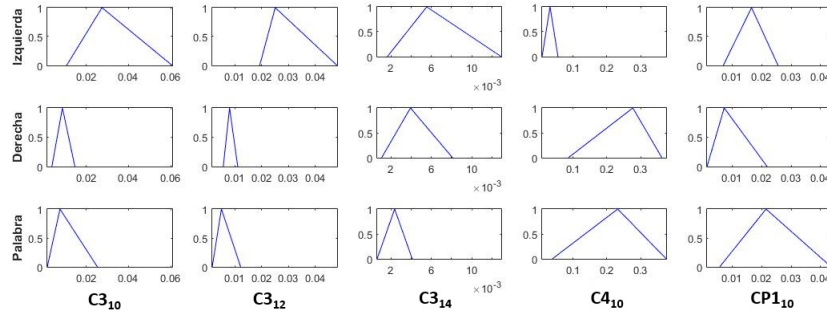


Figura 4.14: Sujeto 1 - Modelo simplificado de tres reglas. Datos BCI Comp

SI  $C3_{10}$  ESTÁ EN  $A_1^D$  Y  $C3_{12}$  ESTÁ EN  $A_2^D$  Y  $C3_{14}$  ESTÁ EN  $A_3^D$  Y  $CP1_{10}$  ESTÁ EN  $A_4^D$  Y  $C4_{10}$  ESTÁ EN  $A_5^D$  ENTONCES “D”

Una representación de las mejores reglas para el Sujeto 1 queda recogida en la Figura 4.14. En ella, cada regla extraída del modelo queda representada por una fila, mientras que las columnas se corresponden con cada una de las características seleccionadas. Así mismo, los valores máximo y mínimo de los ejes de abscisas se han mantenido comunes en la representación de los conjuntos difusos que se corresponden con una misma categoría. De este modo se mejora la legibilidad de las reglas y se facilita el proceso de análisis de las mismas. En cuanto a la interpretabilidad de los datos, se puede decir que:

- La regla asociada a Izquierda -  $I$  muestra sus picos en valores situados en la parte media de la gráfica para los conjuntos difusos en las posiciones  $C3_{10}$ ,  $C3_{12}$  y  $C3_{14}$ , mientras que los valores de activación para la característica  $C4_{10}$  se ubican en la parte inferior del eje de abscisas.
- En la regla generada para Derecha -  $D$  la actividad en las características  $C3_{10}$ ,  $C3_{12}$ ,  $C3_{14}$  decrementa, lo que se puede apreciar porque los picos mostrados se acercan al origen. Sin embargo, la actividad en la componente  $C4_{10}$  incrementa en comparación con las demás.
- La regla asociada a Palabra -  $P$  es bastante similar a la asociada a  $D$  salvo para  $CP1_{10}$ , donde para  $P$  es ciertamente mayor.

En resumen, se puede concluir que patrones de actividad en la mitad del gráfico para la posición  $C3$  tenderían a clasificarse como  $I$ , patrones con actividad en la parte derecha del gráfico para  $C4$  y baja para  $CP1$  se clasificarían como  $D$  y aquellos mostrando actividad alta tanto en  $C4$  como  $CP1$  se clasificarían como  $P$ . Así, se puede intuir que la peor separabilidad se presenta entre las clases  $D$  y  $P$ , lo que es consistente con los valores mostrados por la matriz de confusión (Tabla 4.40), donde se aprecia claramente como predecir  $P$  se confunde mayoritariamente con  $D$ .

Tabla 4.40: Sujeto 1- Matriz de confusión para los datos preprocesados BCI Competition III dataset V en las características del modelo unificado

BCIComp Sujeto 1			
	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	117	9	4
Real Derecha	5	118	5
Real Palabra	8	41	131

Cabe destacar que se han encontrado comportamientos análogos entre modelo de tres de reglas definido para los Sujetos 2 y 3 y el comportamiento de su matriz de confusión.

## 4.4. Conclusiones

Esta sección introduce diferentes deducciones como consecuencia de los resultados mostrados en apartados anteriores. En primer lugar se presenta un análisis de la veracidad de la metodología aportada en comparación con otras existentes en la bibliografía.

Seguidamente, se revisan todos los resultados presentados en los apartados anteriores para la metodología propuesta y se desarrollan los comportamientos comunes a todos ellos. Así, se ofrece una deducción acerca de la evolución en la capacidad de distinguir entre las diferentes tareas, la variante ofreciendo el mejor rendimiento, el número de características requeridas y su distribución espectral o la viabilidad de crear modelos que representen a un amplio número de usuarios.

### 4.4.1. Bondad de metodología

Dado que el BCI Competition III Set V es una base de datos pública ha sido posible encontrar en la literatura diferentes algoritmos de selección de características aplicados sobre este conjunto de datos. Por tanto, se han utilizado éstos para determinar la bondad de la metodología propuesta a partir de los resultados mostrados en la sección 4.2.1. La Tabla 4.41 muestra una comparación de la tasa de éxito en la etapa de clasificación para el conjunto de test evaluando los datos del ganador del BCI Competition ([133]) y los resultados presentados en las referencias [143, 146].

En primer lugar, es destacable que los valores obtenidos a partir de la metodología propuesta en esta tesis doctoral han alcanzado un resultado en media ocho puntos mejor que el conseguido por el campeón del BCI Competition para el mismo experimento.

Igualmente, comparando los resultados con los presentados por Aler et al. ([143]), se ha podido observar que el método estadístico con selección GMDH ha conseguido una precisión en torno a diez puntos mayor para los Sujetos 1 y 2. Además, la metodología de Aler no se ha basado en la selección de características individuales, sino en bandas de frecuencias completas para todos los canales. Por tanto, el número real de componentes en términos comparativos con este estudio (siendo ocho el número de canales en los datos

Tabla 4.41: Comparación de la precisión alcanzada para los datos preprocesados BCI Competition III dataset V entre la metodología propuesta y las mejores alternativas existentes en la literatura

Método de selección	Sujeto 1	Caract.	Sujeto 2	Caract.	Sujeto 3	Caract.	Media
Campeón BCI Competition ([133])	79.60	96	70.31	96	56.02	96	68.65
SVM y con filtros espaciales evolucionados + filtros de selección de frecuencias ([143])	78.14	32	71.33	16	59.07	40	69.58
Mapas EEG [146]	85.71	8	73.80	8	64.28	8	74.60
Estadístico + GMDH	<b>87.64</b>	<b>3</b>	<b>81.57</b>	<b>3</b>	<b>59.40</b>	<b>3</b>	<b>76.20</b>
Difuso + GMDH	<b>89.05</b>	<b>4</b>	<b>82.49</b>	<b>4</b>	<b>57.80</b>	<b>3</b>	<b>76.60</b>

preprocesados de BCI Competition - Dataset V) ha sido de  $4 \times 8 = 32$  características para el Sujeto 1,  $2 \times 8 = 16$  para el Sujeto 2 y  $5 \times 8 = 40$  para el Sujeto 3.

En resumen, los resultados de basados en SVM con filtros espaciados evolucionados y filtros de selección de frecuencias han requerido ocho veces el número de componentes de la aproximación por el método estadístico + GMDH para el Sujeto 1, cinco veces el número para el Sujeto 2 y 13 veces para el Sujeto 3.

Igualmente, en [146] se ha presentado una aproximación basada en la utilización de mapas EEG como representación geométrica de la actividad cerebral, seleccionando una única componente frecuencial para cada usuario (10Hz para el Sujeto 1, 10Hz para el Sujeto 2 y 12Hz para el Sujeto 3). Dado que los mapas, al igual que en el caso anterior, han incluido datos de todos los canales del conjunto datos, en realidad se han tomado ocho características por usuario. Del mismo modo, la cantidad de datos utilizada para crear cada mapa ha ascendido a cinco segundos, lo que infringe la regla que limita a medio segundo la memoria del sistema que establecida para el BCI Competition. Incluso en esta situación ventajosa, el rendimiento alcanzado se ha situado 1.60 puntos por debajo de las aproximaciones Estadística y GMDH aportadas en esta tesis doctoral.

#### 4.4.2. Características de los resultados

En este apartado se evalúan los resultados obtenidos en función de diferentes dimensiones tales como la tasa de éxito alcanzada, el grado de reducción en el número de características de los nuevos modelos o la capacidad de éstos de predecir más acertadamente ciertas tareas. Para ello se utilizan tanto comportamientos individuales, a partir del análisis de los valores mostrados para cada conjunto de datos, como valores genéricos provenientes del estudio de la base de datos EmoExt y del modelo común propuesto.

Se han podido encontrar para los datos BCI Competition III dataset V (BCIComp) conjuntos reducidos de características que han alcanzado mejores tasas de acierto para todos los sujetos, si bien utilizando diferentes variantes de la metodología propuesta. Sin embargo, no se ha podido generalizar este comportamiento dado que para los datos BCI Competition en las posiciones Emotiv (BCIEpoc), los capturados con EasyCap en las posiciones BCI Competition (EasyBCI) y los obtenidos también con EasyCap en las po-

Tabla 4.42: Niveles de acierto alcanzados por los sujetos de las diferentes bases de datos después de aplicar la metodología de selección de características. Se resaltan en azul los niveles de precisión que superaron a los iniciales

Sujeto	Método de selección	Tasa			Acierto Max
		Acierto	No	%	
BCIComp Sujeto 1	Difuso + Orden	89.95	9	9.38	87.21
BCIComp Sujeto 2	Difuso + GMDH	82.49	4	4.17	82.25
EasyBCI Sujeto 1	Difuso + GMDH	78.45	4	4.17	75.52
EmoEpoc Sujeto 1	Difuso + GMDH	67.78	6	3.57	69.04
EasyBCI Sujeto 2	Difuso + GMDH	67.36	5	5.21	65.48
EmoEpoc Sujeto 2	Difuso + Orden	54.21	22	13.10	63.50
BCIEpoc Sujeto 1	Difuso + Orden	64.47	16	9.52	63.40
BCIEpoc Sujeto 2	Difuso + GMDH	57.81	7	4.17	59.07
BCIComp Sujeto 3	Estadístico + GMDH	59.40	3	3.13	58.72
EasyBCI Sujeto 3	Difuso + GMDH	57.11	6	6.25	58.58
EasyEpoc Sujeto 1	Difuso + GMDH	58.58	4	2.38	56.07
EmoEpoc Sujeto 3	Difuso + GMDH	55.72	6	3.57	55.29
EasyEpoc Sujeto 2	Estadístico + GMDH	48.12	3	1.79	54.81
EasyEpoc Sujeto 3	Difuso + GMDH	47.28	3	1.79	47.07
BCIEpoc Sujeto 3	Estadístico + GMDH	44.12	1	0.78	42.23

siciones Emotiv (EasyEpoc) sólo se han incrementado los niveles de acierto de dos de los tres usuarios, reduciéndose la mejora para los capturados con Emotiv EPOC a sólo un sujeto. Analizando por separado los resultados de la base de datos extendida (EmoExt), la metodología aplicada sólo ha aumentado el rendimiento del conjunto completo para 5 de los 12 colaboradores de la muestra (41.66 %), lo que es consistente con el comportamiento de los datos EmoEpoc teniendo en cuenta que se ha utilizado el mismo equipo de detección de señales EEG.

Es decir, atendiendo a las bases de datos de tres usuarios estudiadas y al comportamiento mostrado por la base de datos extendida, la precisión del sistema ha mejorado al utilizar conjuntos reducidos para dos de cada tres usuarios. Asimismo, al analizar los valores presentados en la Tabla 4.42 se ha encontrado que únicamente un valor previo de acierto superior al 75 % ha asegurado un incremento en el nivel de precisión utilizando los modelos reducidos.

Otro parámetro relevante ha sido la variabilidad del sistema prediciendo los diferentes estados. En un sistema BCI ideal, debería ser igualmente probable seleccionar cualquiera de las tres tareas del estudio: Izquierda - *I*, Derecha - *D* y Palabra - *P*. Sin embargo, se ha encontrado en la mayoría de los casos cierta predisposición a predecir Palabra - *P* y una de las tareas motoras muy por encima de la otra. Por ejemplo, si bien para los Sujetos 1 y 2 de la base de datos preprocesada del BCI Competition III dataset V el proceso de selección de características ha nivelado de alguna manera la capacidad del sistema de predecir tareas motoras, para otros sólo se ha reducido mínimamente la diferencia, como para el Sujeto 3 de ese mismo conjunto de datos.

Además, la selección de algunas características ha llegado a incapacitar el sistema para



predecir una de las tareas motoras, como por ejemplo se ha encontrado para los Sujetos 2 y 3 de la base de datos BCIEpoc. Como primera opción se puede asociar este comportamiento a los resultados de la clasificación preliminares. Sin embargo, esta pauta no ha sido consistente e incluso se han encontrado datos que tenían un comportamiento preliminar estable para algunos de los sujetos que han presentado esta tendencia (EmoEpoc Sujeto 3, EasyBCI Sujetos 2 y 3). No obstante, sí que se ha podido asociar el fenómeno mayoritariamente a las componentes seleccionadas por aproximaciones basadas en el método estadístico, que han sido las más propensas a mostrar este tipo de resultados en todos los casos.

Por tanto, los procesos de selección de características pueden tener un efecto adverso en la capacidad de detección de las tareas motoras de manera uniforme. Si bien han podido reducir en algunos casos la brecha existente en el rendimiento prediciendo ambas, también ha existido la posibilidad de que impidan la detección de una de ellas, principalmente si la selección de características subyacente se ha realizado a partir del método estadístico.

Al revisar la variación en el acierto entre la mejor y la peor variante de la metodología han aparecido diferencias desde los dos puntos (BCIComp Sujeto 2 e EasyEpoc Sujeto 2) hasta los 20 (EmoEpoc Sujeto 2), pasando en torno a los 17 para los sujetos BCIEpoc Sujeto 2, EmoEpoc Sujeto 3 o EasyEpoc Sujeto 3. Sin embargo, no se han encontrado patrones en los datos que hayan permitido explicar dicha pauta.

Así mismo, la combinación que ha alcanzado el peor rendimiento ha sido el método estadístico utilizado junto a la selección por orden. Como se ha podido apreciar, no sólo el conjunto de componentes seleccionadas a partir de este criterio no ha logrado el mejor resultado para ninguno de los sujetos de los conjuntos de datos específicos, sino que en media ha ofrecido la capacidad de acierto más discreta para la base de datos EmoExt (42.42 %), siendo más de nueve puntos más baja (18 %) que la mejor opción (51.69 % para el criterio estadístico y la selección por orden) y más de 7.5 peor (15 %) que la combinación entre el criterio difuso y la selección GMDH (49.97 %).

Igualmente, la aproximación basada en el método estadístico y la selección por GMDH ha ofrecido el siguiente resultado más pobre. Para la base de datos EmoExt, el valor medio de acierto se ha quedado en el 43.67 % (15.5 % y 12.6 % peor que para las combinaciones del criterio difuso con la selección por orden y GMDH respectivamente). No obstante, es también remarcable que ha conseguido el mejor resultado para dos de los colaboradores de la base de datos extendida y para el 20 % de los incluidos en los otros conjuntos de datos (Tabla 4.42).

Atendiendo a la base de datos EmoExt, la mejor combinación en la selección de características la han formado el criterio difuso y la selección por orden. Ésta ha alcanzado el mejor resultado medio (51.69 %), siendo 1.72 puntos mejor que la aproximación utilizando selección GMDH. Además, ha logrado los mejores valores de clasificación para cinco de los sujetos incluidos en la base de datos extendida, con aciertos superando al alcanzado con el conjunto completo de características para dos de ellos.

Sin embargo, revisando el contenido de la Tabla 4.42, que también incluye conjuntos de datos cuyos sensores se han ubicado en posiciones distintas a las de Emotiv EPOC (BCIComp y EasyBCI), resulta evidente que la combinación de la metodología ofreciendo los mejores resultados ha sido la formada por el criterio difuso con selección GMDH. Ésta




Figura 4.15: Número de características medio requerido por cada combinación de la metodología de selección de características presentada

ha aparecido como la opción óptima para hasta 9 de los 15 sujetos (60 %), seguida por las variantes basadas en el criterio difuso y la selección por orden y el método estadístico con selección GMDH con tres usuarios cada una (20 %). Además, también ha presentado el mejor resultado para cinco colaboradores en la base de datos EmoExt y ha superado para tres de ellos el umbral marcado por la capacidad de acierto inicial encontrada en sus modelos completos.

Atendiendo al número de características seleccionadas, es clarificador el contenido de la Figura 4.15. En ella se ha representado gráficamente el número medio de componentes elegido por los diferentes métodos de selección para los 12 sujetos. Tal y como se puede apreciar, los más costosos han sido aquellos basados en la selección por orden que, en el caso difuso han requerido 23 características y en la selección por orden casi nueve. En el otro extremo se encuentran las variantes utilizando la selección GMDH, cuya elección ha dado lugar a conjuntos con entre dos y cinco componentes en media.

Teniendo en cuenta la estabilidad en la predicción de las tareas motoras, el número de características requerido y su rendimiento para los diferentes usuarios, el mecanismo óptimo de selección de características para la metodología desarrollada en esta tesis doctoral lo forma la combinación entre el criterio difuso y la selección GMDH.

Así mismo cabe destacar que, exceptuando la base de datos BCIComp, no se han podido encontrar características seleccionadas por todas las variantes de la metodología para cada usuario del conjunto en ninguna base de datos. Es decir, las componentes seleccionadas han presentado una amplia variación entre aproximaciones. Tampoco ha sido posible generalizar un conjunto de características válido para todos los sujetos pertenecientes a cada base de datos.

El intento más relevante de aplicar esta aproximación lo ha ejemplificado el modelo común propuesto para la base de datos EmoExt. En éste sólo se han podido encontrar características formando parte de los conjuntos reducidos para más de tres sujetos para la combinación entre el criterio difuso y la selección por orden. Es decir, como máximo se han encontrado características comunes a un 25 % de los colaboradores de la base de

datos EmoExt para tres de las combinaciones presentadas en la metodología. También se ha podido observar que el rendimiento del clasificador aplicando estas características ha disminuido significativamente, si bien no se ha podido determinar si se ha debido a la información contenida en éstas o a la reducción en el tamaño de los conjuntos de datos disponibles.

Por tanto, no se ha podido encontrar un conjunto de características mínimo que haya ofrecido un nivel de precisión aceptable para todos los sujetos dada la amplia variación inter-usuario en las características seleccionadas para cada combinación de la metodología.

Finalmente, la mayor parte de las características seleccionadas por las metodologías ganadoras se han situado en la banda  $\mu$  del espectro. De hecho, al sumar la banda de 14Hz el número de características ubicadas en la parte baja de espectro se ha situado entre el 54 % (BCI Epoc y EasyEpoc) y el 100 % (conjunto BCIComp). Discutiendo los resultados de un modo más granular se ha podido apreciar que los datos en posiciones BCIComp han concentrado un mayor número de frecuencias entre 8 y 14Hz: del 80 % para los datos EasyBCI al 100 % para el conjunto BCI Comp. Igualmente, los datos capturados en posiciones Emotiv por sistemas diferentes al EPOC han mostrado una mayor dispersión espectral, estando ambos en la parte baja del rango general, con en torno al 54 %. Por último, para la base de datos EmoEpoc, se ha encontrado una concentración del 67 % de las componentes entre 8 y 14Hz, valor contrastado al analizar características comunes a varios sujetos, que se han distribuido en esa banda desde el 52 % para el método estadístico con selección por GMDH hasta el 82 % para el criterio difuso con selección por GMDH (base de datos EmoExt). Este hallazgo es consistente con la literatura, que identifica la banda  $\mu$  y la parte baja del espectro como los espacios que mejor capturan los eventos de ERD y ERS durante la imaginación de movimiento.

#### 4.4.3. Mejora en el tiempo de procesado

El coste de procesado de cada característica añadida al modelo queda definido por:

1. Pre-procesado. Dados los cálculos realizados por la función PSD, basada en periodogramas calculados por el método Welch, el consumo ha sido lineal con el número de características, añadiendo un 1.04 % al total.
2. El clasificador S-dFasArt ha requerido un incremento del 9.21 % en el tiempo de procesado por cada componente durante la generación de los modelos (aprendizaje y poda de reglas), que ha resultado muy significativo considerando que se han de generar 6 modelos para cada usuario.
3. Un incremento final del 7.53 % ha de añadirse a la fase de test para cada característica.



## Capítulo 5

# Conclusiones y Líneas Futuras

### 5.1. Conclusiones

Los resultados obtenidos durante el desarrollo de esta tesis doctoral permiten satisfacer los objetivos presentados al comienzo de este documento dado que:

1. Se ha identificado el dispositivo Emotiv EPOC como un equipo de detección de señales EEG de bajo coste relevante para la comunidad científica.
2. Se ha presentado el problema de imaginación de movimiento multiclase definido en el BCI Competition III dataset V, cuyos datos han sido capturados con un equipo EEG profesional, y que se basa en un paradigma asíncrono y sin realimentación. También se han introducido los algoritmos de preprocesamiento, clasificación y selección de características que han alcanzado los mejores resultados para dicho conjunto de datos.
3. Se han creado cuatro nuevas bases de datos involucrando a más de 19 voluntarios, que han colaborado en una o más sesiones repitiendo el experimento de referencia. De este modo se han obtenido señales cerebrales de tres usuarios con Emotiv EPOC, de cinco sujetos para cada uno de los sistemas basados en EasyCap y de hasta 19 voluntarios para la base de datos extendida de Emotiv EPOC. No obstante, no todos los conjuntos de datos han sido incluidos, ya sea por incidencias en la lectura de los potenciales cerebrales o porque la precisión alcanzada no ha superado el nivel de oportunidad.
4. Se ha demostrado que el sistema BCI construido integrando Emotiv EPOC junto al clasificador S-dFasArt alcanza una precisión asimilable a la lograda sobre datos capturados por equipos de investigación para el problema de referencia a igualdad en la posición de los sensores. Además, la ubicación de los mismos sobre la corteza motora ha posibilitado un incremento de torno al 7 % en el nivel de acierto (desde el 62 % al 66.53 %). Esta mejora aparece como consecuencia de una mejor detección de las variaciones en los ritmos sensimotores durante los procesos de ERD y ERS que tienen lugar durante la imaginación de movimiento. Igualmente, se ha corroborado

la influencia positiva de la realimentación, que ha permitido lograr precisiones de hasta el 75 % con Emotiv EPOC.

5. La metodología de selección de características desarrollada ha conseguido una mayor precisión que la inicial sobre el conjunto completo de componentes para dos de cada tres sujetos. Por tanto, se demuestra que la integración del sistema neurodifuso S-dFasArt con las variantes de la metodología propuesta proporciona resultados óptimos en el proceso de elección de componentes. Además, para rendimientos iniciales superiores al 75 %, siempre se ha podido encontrar un grupo reducido de características que mejora la precisión inicial.
6. La aproximación que ha ofrecido los mejores resultados ha sido la formada por el criterio difuso y la selección GMDH, que además ha logrado una reducción media de 168 a 5 características.
7. Se ha constatado la dificultad de creación de un modelo común para todos los sujetos utilizando esta metodología. La variabilidad de los datos cerebrales ha provocado que las características más representativas, si bien se han concentrado en la banda entre 8 y 14 Hz, hayan sido bastante particulares para cada usuario, por lo que no se ha podido encontrar un conjunto capaz de alcanzar resultados esperanzadores para una población amplia.

Finalmente, se puede concluir que definitivamente el dispositivo EEG Emotiv EPOC supone un paso en la dirección correcta atendiendo a la relación entre su coste y precisión. Los usuarios no han encontrado el uso del mismo intimidante y se puede poner en marcha en menos de cinco minutos. No obstante, el aparato requiere de mejoras ergonómicas que faciliten su uso durante largos periodos de tiempo y, particularmente para los experimentos de imaginación de movimiento, una forma más flexible de situar los electrodos. La metodología de selección de características aportada ha supuesto un avance muy relevante tanto en su capacidad de reducción del conjunto de datos como en el nivel de precisión que alcanzado. Sin embargo, también ha puesto de relieve la variabilidad existente en los datos cerebrales, que impide encontrar un subconjunto de características generalizable entre usuarios.

## 5.2. Líneas futuras

La realización de esta tesis doctoral ha puesto de manifiesto la necesidad de mejoras en ciertas áreas que se describen a continuación:

1. Dispositivos de captura de datos. Nuevos dispositivos de captura de datos EEG de bajo coste deberían permitir una ubicación más flexible de los sensores sobre el cuero cabelludo y maximizar el uso de las tecnologías de sensores secos ([167]). De este modo, se podrían crear sistemas BCI genéricos adaptables a la aplicación requerida por el usuario.

## 2. Experimento:

- a) Problema de analfabetismo BCI (referido en la literatura como *BCI illiteracy*). En torno a un 30 % de los colaboradores no han producido conjuntos de datos con un acierto por encima del nivel aleatorio, lo que está dentro del rango establecido en la literatura ([155]). Sin embargo, no se ha podido determinar si el impedimento ha sido el estado mental temporal del sujeto (estrés, cansancio, consumo reciente de comida...) o si se debe a limitaciones del dispositivo EEG. Un mayor conocimiento en este área permitiría utilizar procedimientos específicos para entrenar a este tipo de usuarios ([125]).
- b) Realimentación y entrenamiento. En esta tesis doctoral se ha incluido un limitado estudio del efecto de la realimentación en la capacidad humana de manejar un sistema BCI existosamente. De hecho, se ha constatado una mejora inmediata en la habilidad del sujeto para operar el mismo. No obstante, se han encontrado resultados contradictorios relacionados con el proceso de aprendizaje del usuario que requieren un estudio más profundo. De este modo, se podría conseguir operar sistemas BCI utilizando Emotiv EPOC con una precisión por encima del 70 % consistentemente.
- c) Tipo de pensamiento:
  - 1) En la captura de datos no se ha establecido ninguna regla en este respecto. Sin embargo, existen variantes como los quasi-movimientos ([168]) que podrían representar una alternativa más efectiva en la generación de potenciales cerebrales detectables.
  - 2) Sería conveniente determinar el número máximo de tareas que se pueden distinguir utilizando el sistema BCI compuesto por Emotiv EPOC junto al clasificador S-dFasArt, así como el tipo de las mismas. El escenario planteado se basa en dos tareas motoras y una, la imaginación de palabras comenzando por una misma letra, que no lo es. Sería interesante conocer resultado de aplicar otras alternativas ([169, 157, 170, 17, 156]).
- d) Cantidad de datos para el cálculo de una salida. Sería necesaria la evaluación del conjunto de datos que maximiza la precisión de la salida sin atender a restricciones externas.

## 3. Clasificación:

- a) Latencia. Los experimentos con realimentación y los gráficos mostrando el comportamiento de las sesiones de entrenamiento han puesto de manifiesto la existencia de una latencia entre el momento en el que se marca el cambio de tarea y el cambio efectivo. Resultaría un gran avance cara a medir la precisión real de los sistemas BCI calcular ese tiempo mínimo, que sería el que necesita el usuario para modelar su pensamiento después de una transición. Igualmente, existen estudios que reportan una latencia variable en la medición de ERPs para Emotiv EPOC en comparación con sistemas de investigación (entre los 8.1 y los 125 ms) que sería preciso verificar ([117, 118]).

- b)* Aprendizaje on-line. Los sistemas BCI deberían ser operacionales desde que se sacan de su embalaje, por lo que sería necesario que éstos incluyesen algún tipo de entrenamiento previo que ayudase al usuario a utilizar los equipos durante los primeros instantes. Así, el proceso de aprendizaje sería más natural ya que tanto el consumidor como el dispositivo aprenderían del otro durante las primeras sesiones.

#### 4. Aplicaciones:

- a)* La integración de sistemas BCI con prótesis rehabilitadoras de bajo coste tendría un público potencial en torno a ocho millones de personas a nivel mundial cada año. De este modo, se facilitaría, acortaría y abarataría el proceso de recuperación de los pacientes que sufren accidentes cerebrovasculares.
- b)* Sistemas que requieren nuevos grados de libertad. En sistemas médicos en los que el cirujano revisa a las pruebas diagnósticas de un paciente utilizando gafas de realidad aumentada mientras realiza la cirugía, el acceso a las mismas sin requerir las manos sería ciertamente ventajoso.
- c)* Operación de exoesqueletos y miembros artificiales. Rehabilitar el movimiento independiente de personas que han perdido esa capacidad es sin duda el mayor reto de la tecnología.



# Bibliografía

- [1] World Health Organization, “Global burden of stroke.” [http://www.who.int/cardiovascular\\_diseases/en/cvd\\_atlas\\_15\\_burden\\_stroke.pdf?ua=1](http://www.who.int/cardiovascular_diseases/en/cvd_atlas_15_burden_stroke.pdf?ua=1), 2004. Accedido 2018-11-18.
- [2] A. Di Carlo, “Human and economic burden of stroke,” *Age and Ageing*, vol. 38, no. 1, pp. 4–5, 2009.
- [3] World Health Organization, “Spinal cord injury.” <http://www.who.int/news-room/fact-sheets/detail/spinal-cord-injury>, Nov. 2013. Accedido 2018-11-18.
- [4] Forbes, “Elderly and disabled assistive technology market to surpass \$26 billion by 2024.” <https://www.forbes.com/sites/tjmccue/2017/03/21/elderly-and-disabled-assistive-technology-market-to-surpass-26-billion-by-2024/>, Mar. 2017. Accedido 2018-11-18.
- [5] Gartner, “Hype cycle for emerging technologies, 2018.” [https://blogs.gartner.com/smarterwithgartner/files/2018/08/PR\\_490866\\_5\\_Trends\\_in\\_the\\_Emerging\\_Tech\\_Hype\\_Cycle\\_2018\\_Hype\\_Cycle.png](https://blogs.gartner.com/smarterwithgartner/files/2018/08/PR_490866_5_Trends_in_the_Emerging_Tech_Hype_Cycle_2018_Hype_Cycle.png), Aug. 2018. Accedido 2018-11-18.
- [6] J. Wolpaw, L. G.E., B. Allison, E. Donchin, O. do Nascimento, W. Heetderks, F. Nijboer, W. Shain, and J. Turner, “BCI Meeting 2005-Workshop on signals and recording methods,” *IEEE Transactions on neural systems and rehabilitation engineering*, vol. 14, no. 2, pp. 138–141, 2006.
- [7] F. Cincotti, L. Bianchi, G. Birch, C. Guger, J. Mellinger, R. Scherer, R. Schmidt, O. Yáñez Suárez, and G. Schalk, “BCI Meeting 2005-Workshop on technology: hardware and software,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, no. 2, pp. 128–131, 2006.
- [8] Wikipedia, “Sistema nervioso central.” [https://es.wikipedia.org/wiki/Sistema\\_nervioso\\_central](https://es.wikipedia.org/wiki/Sistema_nervioso_central). Accedido 2018-11-18.
- [9] J. Kiernan and N. Rajakumar, *Barr’s The Human Nervous System: An Anatomical Viewpoint*. Lippincott Williams & Wilkins, 2013.

- [10] C. R. Noback, N. L. Strominger, R. J. Demarest, and D. A. Ruggiero, *The human nervous system: structure and function*. No. 744, Springer Science & Business Media, 2005.
- [11] J. Ross, D. Lasserson, C. Gabriel, B. Sharrack, C. Briar, M. Hughes, and T. Miller, *Crash Course: Nervous Ssystem Updated Edition*. Elsevier, 2015.
- [12] F. Evans-Martin, *The Nervous System*. Chelsea House, 2005.
- [13] Icarito, “Centros nerviosos del cerebro.”  
<http://www.icarito.cl/2010/05/centros-nerviosos-del-cerebro.shtml/>, 2018. Accedido 2018-11-18.
- [14] Carpeta Pedagógica. Plataforma Educativa de Recursos Digitales, “Características y funciones de la médula espinal.”  
<http://cienciasnaturales.carpetapedagogica.com/2013/12/Caracteristicas-funciones-medula-espinal.html>, 2013. Accedido 2018-11-18.
- [15] L. Vokorokos, B. Mados, N. Ádám, and A. Baláz, “Data Acquisition in Non-Invasive Brain-Computer Interface Using Emotiv Epoc Neuroheadset,” *Acta Electrotechnica et Informatica*, vol. 12, no. 1, pp. 5–8, 2012.
- [16] B. Zhang, J. Wang, and T. Fuhlbrigge, “A review of the commercial brain-computer interface technology from perspective of industrial robotics,” in *Proceedings of the 2010 IEEE International Conference on Automation and Logistics*, 2010.
- [17] J. d. R. Millán, F. Galán, D. Vanhooydonck, E. Lew, J. Philips, and M. Nuttin, “Asynchronous non-invasive brain-actuated control of an intelligent wheelchair,” in *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 3361–3364, IEEE, 2009.
- [18] J. Collinger, B. Wodlinger, D. J.E., W. Wang, E. Tyler-Kabaa, D. Weber, A. McMorland, M. Velliste, M. Boninger, and A. Schwartz, “High-performance neuroprosthetic control by an individual with tetraplegia,” *The Lancet*, pp. 1–8, 2012.
- [19] J. d. R. Millan and J. M. Carmena, “Invasive or noninvasive: Understanding brain-machine interface technology [conversations in BME],” *IEEE Engineering in Medicine and Biology Magazine*, vol. 29, no. 1, pp. 16–22, 2010.
- [20] R. Wolpaw, N. Birbaumer, D. McFarland, G. Pfurtscheller, and T. Vaughan, “Brain-computer interfaces for communication and control,” *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [21] A. Schwartz, X. T. Cui, D. Weber, and D. W. Moran, “Brain-controlled interfaces: movement restoration with neural prosthetics,” *Neuron*, vol. 52, no. 1, pp. 205–220, 2006.

- [22] N. J. Hill, D. Gupta, P. Brunner, A. Gunduz, M. A. Adamo, A. Ritaccio, and G. Schalk, "Recording human electrocorticographic (ECoG) signals for neuroscientific research and real-time functional cortical mapping," *JoVE (Journal of Visualized Experiments)*, vol. 64, p. e3993, 2012.
- [23] N. J. Hill, T. N. Lal, M. Schröder, T. Hinterberger, G. Widman, C. E. Elger, B. Schölkopf, and N. Birbaumer, "Classifying event-related desynchronization in EEG, ECoG and MEG signals," in *Joint Pattern Recognition Symposium*, pp. 404–413, Springer, 2006.
- [24] NeurotechEdu, "Intro to brain computer interface."  
<http://learn.neurotechedu.com/introtobci/>. Accedido 2018-11-18.
- [25] Biomedical+, "A recent updates on biomedical engineering."  
<http://devendradesmukh.blogspot.com/2012/10/fmri.html>, Oct. 2012.  
Accedido 2018-11-18.
- [26] NeuroSpec Research Neurosciences, "NIRS."  
<https://www.neurospec.com/Products/Hardware/Overview/NIRS>. Accedido 2018-11-18.
- [27] H. AlZu'bi, N. Al-Zubi, and W. Al-Nuaimy, "Toward inexpensive and practical Brain Computer Interface," in *Developments in E-systems Engineering (DeSE)*, 2011.
- [28] Biosemi, "Start your analysis with clean signals from Biosemi systems!"  
<https://www.biosemi.com/>, 2018. Accedido 2018-11-18.
- [29] D. Juang, "EEG electrode placement for Motor Imagery."  
<https://drhrdro.wordpress.com/2013/09/11/eeg-electrode-placement-for-motor-imagery-y01-m01-d10/>, Sept. 2013.  
Accedido 2018-11-18.
- [30] A. Kostov and M. Polak, "Parallel man-machine training in development of EEG-based cursor control," *IEEE Transaction on Rehabilitation Engineering*, vol. 8, pp. 203–205, June 2000.
- [31] T. Hinterberger, R. Veit, U. Strehl, T. Trevorrow, M. Erb, B. Kotchoubey, H. Flor, and N. Birbaumer, "Brain areas activated in fMRI during self-regulation of slow cortical potentials (SCPs)," *Experimental brain research*, vol. 152, no. 1, pp. 113–122, 2003.
- [32] N. Birbaumer and L. G. Cohen, "Brain-computer interfaces: communication and restoration of movement in paralysis," *The Journal of Physiology*, vol. 579, no. 3, pp. 621–636, 2007.
- [33] G. Pfurtscheller and F. L. Da Silva, "Event-related EEG/MEG synchronization and desynchronization: basic principles," *Clinical neurophysiology*, vol. 110, no. 11, pp. 1842–1857, 1999.

- [34] G. Pfurtscheller and C. Neuper, "Frequency component selection for an EEG-based brain to computer interface," *IEEE Transaction on Rehabilitation Engineering*, vol. 7, pp. 413–419, 1997.
- [35] G. Pfurtscheller and C. Neuper, "Motor imagery activates primary sensorimotor area in humans," *Neuroscience letters*, vol. 239, no. 2, pp. 65–68, 1997.
- [36] D. McFarland and R. Wolpaw, "Sensorimotor Rhythm-Based Brain–Computer Interface (BCI): Feature Selection by Regression Improves Performance," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 13, pp. 372–379, September 2005.
- [37] G. Rosas-Cholula, J. Ramírez-Cortes, V. Alarcón-Aquino, J. Martínez-Carballido, and P. Gómez-Gil, "On signal P-300 detection for BCI applications based on wavelet analysis and ICA preprocessing," in *Electronics, Robotics and Automotive Mechanics Conference*, 2010.
- [38] L. A. Farwell and E. Donchin, "Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials," *Electroencephalography and clinical Neurophysiology*, vol. 70, no. 6, pp. 510–523, 1988.
- [39] R. Fazel-Rezai, B. Z. Allison, C. Guger, E. W. Sellers, S. C. Kleih, and A. Kübler, "P300 brain computer interface: current challenges and emerging trends," *Frontiers in neuroengineering*, vol. 5, 2012.
- [40] R. Panicker, S. Puthusserypady, and Y. Sun, "An asynchronous P300 BCI with SSVEP-based control state detection," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 6, pp. 1781–1788, 2011.
- [41] F. Guo, B. Hong, X. Gao, and S. Gao, "A brain-computer interface using motion-onset visual evoked potential," *Journal of Neural Engineering*, vol. 5, no. 4, p. 477, 2008.
- [42] B. Hong, F. Guo, T. Liu, X. Gao, and S. Gao, "N200-speller using motion-onset visual response," *Clinical Neurophysiology*, vol. 120, no. 9, pp. 1658–1666, 2009.
- [43] D. Zhang, H. Song, H. Xu, W. Wu, S. Gao, and B. Hong, "An N200 speller integrating the spatial profile for the detection of the non-control state," *Journal of Neural Engineering*, vol. 9, no. 2, p. 026016, 2012.
- [44] S. Amiri, R. Fazel-Rezai, and V. Asadpour, "A review of hybrid brain-computer interface systems," *Advances in Human-Computer Interaction*, vol. 2013, pp. 1–8, 2013.
- [45] E. Yin, Z. Zhou, J. Jiang, F. Chen, Y. Liu, and D. Hu, "A novel hybrid BCI speller based on the incorporation of SSVEP into the P300 paradigm," *Journal of neural engineering*, vol. 10, no. 2, p. 026012, 2013.

- [46] Y. Li, J. Pan, F. Wang, and Z. Yu, “A hybrid BCI system combining P300 and SSVEP and its application to wheelchair control,” *IEEE Transactions on Biomedical Engineering*, vol. 60, pp. 3156–3165, November 2013.
- [47] Brain Products, “Brain Products - Solutions for neurophysiological research.” <http://www.brainproducts.com/>. Accedido 2018-11-18.
- [48] Ant Neuro, “Ant Neuro - Inspiring Technology.” <http://www.ant-neuro.com/>, 2018. Accedido 2018-11-18.
- [49] g.tec, “g.tec medical engineering.” <http://www.gtec.at/>, 2018. Accedido 2018-11-18.
- [50] Neuroelectronics, “Products / Enobio.” <http://www.neuroelectronics.com/products/enobio/>, 2018. Accedido 2018-11-18.
- [51] Neurosky, “Body and Mind. Quantified.” <http://neurosky.com/>, 2017. Accedido 2018-11-18.
- [52] Emotiv, “Emotiv products.” <https://www.emotiv.com/>, 2018. Accedido 2018-11-18.
- [53] OpenBCI, “OpenBCI - Getting Started.” <http://docs.openbci.com/Getting%20Started/00-Welcome>, 08 2017. Accedido 2018-11-18.
- [54] Muse, “Muse - The brain sensing headband.” <http://www.choosemuse.com/>, 2017. Accedido 2018-11-18.
- [55] P. Mavros, R. Coyne, J. Roe, and P. Aspinall, “Engaging the brain. implications of mobile EEG for spatial representation,” in *eCAADe Conference*, (Prague, Czech Republic), 2012.
- [56] G. Ranky and S. Adamovich, “Analysis of a commercial EEG device for the control of a robot arm,” in *Bioengineering Conference, Proceedings of the 2010 IEEE 36th Annual Northeast*, March 2010.
- [57] S. Rojas, J. Garzón, D. Martínez, M. Escobar, C. Robayo, and D. Montenegro, “Lector de ondas cerebrales para implementar un sistema alternativo y aumentativo de comunicación,” in *enth LACCEI Latin American and Caribbean Conference - International Competition of Student Posters and Papers*, 2012.
- [58] K. Krishnaswamy and R. Kuber, “Toward the development of a BCI and gestural interface to support individuals with physical disabilities,” in *In proceedings of the 14th International ACM Conference on Computers and Accessibility*, pp. 229–230, 2012.

- [59] R. Scherer, M. Pröll, B. Allison, and G. Müller-Putz, “New input modalities for modern game design and virtual embodiment,” in *Virtual Reality Short Papers and Posters (VRW)*, 2012.
- [60] D. Sinyukov, R. Li, N. Otero, R. Gao, and T. Padir, “Augmenting a voice and facial expression control of a robotic wheelchair with assistive navigation,” in *Systems, Man and Cybernetics (SMC), 2014 IEEE International Conference on*, pp. 1088–1094, IEEE, 2014.
- [61] H. Nisar, Q. Yeoh, H. Balasubramaniam, W. Wei, and A. Malik, “Analysis of brain activity while performing cognitive actions to control a car,” in *The 15th International Conference on Biomedical Engineering*, pp. 947–950, Springer, 2014.
- [62] S. Shankar and R. Rai, “Human factors study on the usage of BCI headset for 3D CAD modeling,” *Computer-Aided Design*, vol. 54, pp. 51–55, 2014.
- [63] F. Ben Taher, N. Ben Amor, M. Jallouli, A. Ben Hammouda, and O. Dghim, “A collaborative and voice configured electric powered wheelchair control system based on eeg and head movement,” in *3rd International Conference on Automation, Control Engineering and Computer Science*, 2016.
- [64] B. Madoš, N. Adam, J. Hurtuk, and M. Čopjak, “Brain-computer interface and arduino microcontroller family software interconnection solution,” in *Applied Machine Intelligence and Informatics (SAMi), 2016 IEEE 14th International Symposium on*, pp. 217–221, IEEE, 2016.
- [65] W. Alrajhi, D. Alaloola, and A. Albarqawi, “Smart home: toward daily use of BCI-based systems,” in *Informatics, Health & Technology (ICIHT), International Conference on*, pp. 1–5, IEEE, 2017.
- [66] D. Cernea, P. Olech, A. Ebert, and A. Kerren, “EEG-based measurement of subjective parameters in evaluations,” in *Communications in Computer and Information Science*, vol. 174, pp. 279–283, HCI International 2011 – Posters’ Extended Abstracts, Springer, 2011.
- [67] H. Hamdi, P. Richard, A. Suteau, and P. Allain, “Emotion assessment for affective computing based on physiological responses,” in *WCCI 2012 IEEE World Congress on Computational Intelligence*, 2012.
- [68] R. Kuber and F. Wright, “Augmenting the instant messaging experience through the use of Brain–Computer Interface and gestural technologies,” *International Journal of Human-Computer Interaction*, vol. 29, pp. 178–191, January 2013.
- [69] J. Seigneux, “The emotional economy for the augmented human,” in *Proceedings of the 2nd Augmented Human International Conference*, 2011.
- [70] A. Moldovan, I. Gergulescu, and C. Muntean, “Analysis of Learner Interest, QoE and EEG-Based Affective States in Multimedia Mobile Learning,” in *Advanced*

- Learning Technologies (ICALT)*, 2017 IEEE 17th International Conference on, pp. 398–402, IEEE, 2017.
- [71] A. Shirazi, M. Funk, F. Pfeiderer, H. Glück, and A. Schmidt, “MediaBrain: Annotating videos based on Brain-Computer Interaction,” in *Mensch & Computer 2012: 12. fachübergreifende Konferenz für interaktive und kooperative Medien*, 2012.
  - [72] S. Verkijika and L. De Wet, “Using a brain-computer interface (BCI) in reducing math anxiety: Evidence from South Africa,” *Computers & Education*, vol. 81, pp. 113–122, 2015.
  - [73] I. Ghergulescu and C. Muntean, “ToTCompute: A Novel EEG-Based TimeOnTask Threshold Computation Mechanism for Engagement Modelling and Monitoring,” *International Journal of Artificial Intelligence in Education*, vol. 26, no. 3, pp. 821–854, 2016.
  - [74] R. Ghali, S. Ouellet, and C. Frasson, “Lewispace: An exploratory study with a machine learning model in an educational game,” *Journal of Education and Training Studies*, vol. 4, no. 1, pp. 192–201, 2016.
  - [75] S. Tilley, C. Neale, A. Patuano, and S. Cinderby, “Older People’s Experiences of Mobility and Mood in an Urban Environment: A Mixed Methods Approach Using Electroencephalography (EEG) and Interviews,” *International journal of environmental research and public health*, vol. 14, no. 2, pp. 1–20, 2017.
  - [76] A. Fattouh, O. Horn, and G. Bourhis, “Emotional BCI control of a smart wheelchair,” *IJCSI International Journal of Computer Science Issues*, vol. 10, pp. 32–36, May 2013.
  - [77] S. Guo, X. Zhao, W. Wei, J. Guo, F. Zhao, and Y. Hu, “Feasibility study of a novel rehabilitation training system for upper limb based on emotional control,” in *Mechatronics and Automation (ICMA)*, 2015 IEEE International Conference on, pp. 1507–1512, IEEE, 2015.
  - [78] A. Thobbi, R. Kadam, and W. Sheng, “Achieving remote presence using a humanoid robot controlled by a non-invasive BCI device,” *ICGST International Journal on Automation, Robotics and Autonomous Systems*, vol. 10, pp. 41–45,, 2010.
  - [79] A. Vourvopoulos and F. Liarokapis, “Robot navigation using Brain-Computer Interfaces,” in *IEEE 11th International Conference on Trust, Security and Privacy in Computing and Communications*, 2012.
  - [80] G. Taylor and C. Schmidt, “Empirical evaluation of the Emotiv EPOC BCI headset for the detection of mental actions,” in *Proceedings of the Human Factors and Ergonomics Society Annual Meeting 2012*, pp. 193–197, Sage, 2012.

- [81] G. Sepúlveda Cervantes, N. Montaña Martínez, and M. Román Pérez, “Interfaz cerebro computadora para el posicionamiento de un robot virtual,” *Universidad Autónoma Metropolitana México*, 2012.
- [82] Y. Luo and Y. Shen, “Brain-driven micro-biomanipulation with sensing feedback,” in *Proceedings of the 10th World Congress on Intelligent Control and Automation*, 2012.
- [83] A. Vourvopoulos, F. Liarokapis, and P. Petridis, “Brain-controlled serious games for cultural heritage,” in *Virtual Systems and Multimedia (VSMM), 2012 18th International Conference on Virtual Systems and Multimedia (VSMM), 2012 18th International Conference on 18th International Conference on Virtual Systems and Multimedia (VSMM)*, 2012.
- [84] J. Webb, Z. Xiao, K. Aschenbrenner, G. Herrnsstadt, and C. Menon, “Towards a portable assistive arm exoskeleton for stroke patient rehabilitation controller through a brain computer interface,” in *The Fourth IEEE RAS/EMBS International Conference on Biomedical Robotics and Biomechatronics*, (Roma, Italy), 2012.
- [85] P. Chowdhury, S. K. Shakim, R. Karim, and K. Rhaman, “Cognitive Efficiency in Robot Control by Emotiv EPOC,” in *Informatics, Electronics & Vision (ICIEV), 2014 International Conference on*, pp. 1–6, IEEE, 2014.
- [86] S. Swee and L. You, “Fast Fourier analysis and EEG classification brainwave controlled wheelchair,” in *Control Science and Systems Engineering (ICCSSE), 2016 2nd International Conference on* (20–23, ed.), IEEE, 2016.
- [87] G. Barresi, J. Tessadori, L. Schiatti, D. Mazzanti, D. Caldwell, and L. Mattos, “Focus-sensitive dwell time in EyeBCI: Pilot study,” in *Computer Science and Electronic Engineering (CEECE), 2016 8th*, pp. 54–59, IEEE, 2016.
- [88] L. Schiatti, J. Tessadori, G. Barresi, L. Mattos, and A. Ajoudani, “Soft brain-machine interfaces for assistive robotics: A novel control approach,” in *Rehabilitation Robotics (ICORR), 2017 International Conference on*, pp. 863–869, IEEE, 2017.
- [89] B. Shah, “Humanoid robot controlled by remote presence using non-invasive BCI device,” in *3rd International Conference on Emerging Technologies in Engineering, Biomedical, Management and Science*, 2017.
- [90] C. Tabernig, C. Lopez, L. Carrere, E. Spaich, and C. Ballario, “Neurorehabilitation therapy of patients with severe stroke based on functional electrical stimulation commanded by a brain computer interface,” *Journal of Rehabilitation and Assistive Technologies Engineering*, vol. 5, p. 2055668318789280, 2018.



- [91] S. O' Regan, S. Faul, and W. Marnane, "Automatic detection of EEG artefacts arising from head movements," in *32nd Annual International Conference of the IEEE EMBS*, 2010.
- [92] A. Campbell, T. Choudhury, S. Hu, H. Lu, M. Mukerjee, M. Rabbi, and R. Raizada, "Neurophone: Brain-mobile phone interface using a wireless EEG headset." <http://www.cs.dartmouth.edu/~campbell/papers/neurophone.pdf>, 2010.
- [93] S. Choudhury, "Learning thought-based motor control using Gaussian processes." <https://ece.uwaterloo.ca/~schoudhu/assets/projects/syde422paper.pdf>.
- [94] S. Fok, R. Schwartz, M. Wronkiewicz, C. Holmes, J. Zhang, T. Somers, D. Bundy, and E. Leuthardt, "An EEG-based Brain Computer Interface for rehabilitation and restoration of hand control following stroke using ipsilateral cortical physiology," in *33rd Annual International Conference of the IEEE EMBS*, 2011.
- [95] I. Martinovic, D. Davies, M. Frank, D. Perito, T. Ros, and D. Song, "On the feasibility of side-channel attacks with Brain-Computer Interfaces," in *USENIX Security Conference*, 2012.
- [96] D. Cernea, P. Olech, A. Ebert, and A. Kerren, "Controlling in-vehicle systems with a commercial EEG headset: Performance and cognitive load," in *Visualization of Large and Unstructured Data Sets: Applications in Geospatial Planning, Modeling and Engineering - Proceedings of IRTG 1131 Workshop 2011* (C. Garth, A. Middel, and H. Hagen, eds.), vol. 27 of *OpenAccess Series in Informatics (OASICS)*, (Dagstuhl, Germany), pp. 113–122, Schloss Dagstuhl-Leibniz-Zentrum fuer Informatik, 2012.
- [97] S. Soman, S. Gupta, and P. Raj, "Non invasive Brain Computer Interface for controlling user desktop," in *Centre for Development of Advanced Computing*, 2012.
- [98] F. Carrino, J. Dumoulin, E. Mugellini, O. Khaled, and R. Ingold, "A self-paced BCI system to control an electric wheelchair: evaluation of a commercial, low-cost EEG device," in *Biosignals and Biorobotics Conference (BRC)*, 2012.
- [99] C. Holmes, M. Wronkiewicz, T. Somers, Y. Liu, E. Russell, D. Kim, C. Rhoades, J. Dunkley, D. Bundy, E. Galboa, and E. Leuthardt, "IPSIHAND BRAVO: An improved EEG-based Brain-Computer Interface for hand motor control rehabilitation," in *34th Annual International Conference of the IEEE EMBS*, 2012.
- [100] D. Prince, M. Edmonds, A. Sutter, M. Cusumano, W. Lu, and V. Asari, "Brain machine interface using Emotiv EPOC to control robai cyton robotic arm," in *Aerospace and Electronics Conference (NAECON), 2015 National*, pp. 263–266, IEEE, 2015.
- [101] M. Fakhruzzaman, E. Riksakomara, and H. Suryotrisongko, "EEG Wave Identification in Human Brain with Emotiv EPOC for Motor Imagery," *Procedia Computer Science*, vol. 72, pp. 269–276, 2015.

- [102] H. Shedeed and M. Issa, “Brain-EEG signal classification based on data normalization for controlling a robotic arm,” *International Journal of Tomography and Simulation*, vol. 29, no. 1, pp. 72–85, 2016.
- [103] B. Petrov, E. Stamenova, and N. Petrov, “Brain-computer interface as internet of things device,” in *Scientific Conference Electronics (ET), International*, pp. 1–4, IEEE, 2016.
- [104] W. Hsu, “An integrated-mental brainwave system for analyses and judgments of consumer preference,” *Telematics and Informatics*, vol. 34, no. 5, pp. 518–526, 2017.
- [105] J. Shin, K. Müller, C. Schmitz, D. Kim, and H. Hwang, “Evaluation of a compact hybrid brain-computer interface system,” *BioMed research international*, vol. 2017, 2017.
- [106] S. Debener, F. Minow, R. Emkes, K. Gandras, and M. Vos, “How about taking a low-cost, small, and wireless EEG for a walk?,” *Psychophysiology*, vol. 49, pp. 1449–1453, 2012.
- [107] F. Bodranghien, M. Langlois Mahe, S. Clément, and M. Manto, “A pilot study on the effects of transcranial direct current stimulation on brain rhythms and entropy during self-paced finger movement using the Epoc helmet,” *Frontiers in human neuroscience*, vol. 11, p. 201, 2017.
- [108] S. K. Haider, M. I. Daud, A. Jiang, and Z. Khan, “Evaluation of P300 based Lie Detection Algorithm,” *Electrical and Electronic Engineering*, vol. 7, no. 3, pp. 69–76, 2017.
- [109] R. Li, X. Zhang, H. Li, L. Zhang, Z. Lu, and J. Chen, “An approach for brain-controlled prostheses based on Scene Graph Steady-State Visual Evoked Potentials,” *Brain research*, vol. 1692, pp. 142–153, 2018.
- [110] J. Kilmarx, R. Abiri, S. Borhani, Y. Jiang, and X. Zhao, “Sequence-based manipulation of robotic arm control in brain machine interface,” *International Journal of Intelligent Robotics and Applications*, vol. 2, no. 2, pp. 149–160, 2018.
- [111] R. Saini, B. Kaur, P. Singh, P. Kumar, P. P. Roy, B. Raman, and D. Singh, “Don’t just sign use brain too: A novel multimodal approach for user identification and verification,” *Information Sciences*, vol. 430, pp. 163–178, 2018.
- [112] K. Kotowski, K. Stapor, J. Leski, and M. Kotas, “Validation of Emotiv EPOC+ for extracting ERP correlates of emotional face processing,” *Biocybernetics and Biomedical Engineering*, vol. 38, no. 4, pp. 773–781, 2018.
- [113] Y. Liu, X. Jiang, T. Cao, F. Wan, P. Mak, P. Mak, and M. Vai, “Implementation of SSVEP based BCI with Emotiv EPOC,” in *Virtual Environments Human-Computer Interfaces and Measurement Systems (VECIMS)*, pp. 34–7, 2012.

- [114] M. Van Vliet, A. Robben, N. Chumerin, N. Manyakov, A. Combaz, and M. Van Hulle, "Designing a Brain-Computer Interface controlled video-game using consumer grade EEG hardware," in *Biosignals and Biorobotics Conference (BRC)*, 2012.
- [115] A. McConnell, M. Vallejo, R. Moioli, F. Brasil, N. Secciani, M. Nemitz, C. Riquart, D. Corne, P. Vargas, and A. Stokes, "Sophia: Soft orthotic physiotherapy hand interactive aid," *Frontiers in Mechanical Engineering*, vol. 3, no. 3, 2017.
- [116] M. Duvinage, T. Castermans, M. Petieau, T. Hoellinger, G. Cheron, and T. Dutoit, "Performance of the Emotiv Epoc headset for P300-based applications," *Biomedical engineering online*, vol. 12, no. 1, pp. 1–15, 2013.
- [117] A. Ries, J. Touryan, J. Vettel, K. McDowell, and W. Hairston, "A comparison of electroencephalography signals acquired from conventional and mobile systems," *Journal of Neuroscience and Neuroengineering*, vol. 3, no. 1, pp. 10–20, 2014.
- [118] N. Badcock, K. Preece, B. de Wit, K. Glenn, N. Fieder, J. Thie, and G. McArthur, "Validation of the Emotiv EPOC EEG system for research quality auditory event-related potentials in children," *PeerJ*, vol. 3, no. 1-17, 2015.
- [119] P. de Lissa, S. Sörensen, N. Badcock, J. Thie, and G. McArthur, "Measuring the face-sensitive N170 with a gaming EEG system: a validation study," *Journal of Neuroscience Methods*, vol. 253, pp. 47–54, June 2015.
- [120] EasyCap, "EASYCAP - EEG Recording Caps and Related Products." <https://www.easycap.de/wordpress/>, 2018. Accedido 2018-11-18.
- [121] F. Munoz-Sanchez, "Construcción de una nueva interfaz cerebro-computadora a partir de una de bajo coste (Emotiv EPOC)," Master's thesis, Universidad Politécnica de Cartagena, 2015.
- [122] B. Blankertz, K. Muller, D. J. Krusienski, G. Schalk, J. Wolpaw, A. Schlogl, G. Pfurtscheller, J. Millan, M. Schroder, and N. Birbaumer, "The BCI competition III: Validating alternative approaches to actual BCI problems," *IEEE transactions on neural systems and rehabilitation engineering*, vol. 14, no. 2, pp. 153–159, 2006.
- [123] M. Tangermann, K. Müller, A. Aertsen, N. Birbaumer, C. Braun, C. Brunner, R. Leeb, C. Mehring, K. Miller, G. Müller-Putz, *et al.*, "Review of the BCI competition IV," *Frontiers in neuroscience*, vol. 6, 2012.
- [124] B. Blankertz, R. Tomioka, S. Lemm, M. Kawanabe, and K. Muller, "Optimizing spatial filters for robust EEG single-trial analysis," *IEEE Signal processing magazine*, vol. 25, no. 1, pp. 41–56, 2008.
- [125] R. Maskeliunas, R. Damasevicius, I. Martisius, and M. Vasiljevas, "Consumer-grade EEG devices: are they usable for control tasks?," *PeerJ*, vol. 4, 2016.

- [126] D. McFarland, L. McCane, S. David, and R. Wolpaw, "Spatial filter selection for EEG-based communication," *Electroencephalography and clinical Neurophysiology*, vol. 103, pp. 386–394, 1997.
- [127] F. Babiloni, F. Cincotti, L. Bianchi, G. Pirri, J. Millán, J. Mouriño, S. Salinari, and M. Marciani, "Recognition of imagined hand movements with low resolution surface Laplacian and linear classifiers," *Medical engineering & physics*, vol. 23, no. 5, pp. 323–328, 2001.
- [128] A. Bashashati, M. Fatourehchi, R. Ward, and G. Birch, "A survey of signal processing algorithms in brain–computer interfaces based on electrical brain signals," *Journal of Neural Engineering*, vol. 4, pp. 32–57, 2007.
- [129] G. Dornhege, B. Blankertz, G. Curio, and K. Muller, "Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms," *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 993–1002, 2004.
- [130] W. Wu, X. Gao, and S. Gao, "One-versus-the-rest (OVR) algorithm: An extension of common spatial patterns (CSP) algorithm to multi-class case," in *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the* (2387–2390, ed.), IEEE, 2005.
- [131] T. Yan, T. Jingtian, and G. Andong, "Multi-class EEG classification for brain computer interface based on CSP," in *BioMedical Engineering and Informatics, 2008. BMEI 2008. International Conference on*, vol. 2, pp. 469–472, IEEE, 2008.
- [132] M. Naeem, C. Brunner, R. Leeb, B. Graimann, and G. Pfurtscheller, "Seperability of four-class motor imagery data using independent components analysis," *Journal of Neural Engineering*, vol. 3, no. 3, pp. 208–216, 2006.
- [133] F. Galán, F. Oliva, and J. Guardia, "Using mental tasks transitions detection to improve spontaneous mental activity classification," *Medical & biological engineering & computing*, vol. 45, no. 6, pp. 603–609, 2007.
- [134] N. Irtiza and H. Farooq, "Classification of brain states using subject-specific trained classifiers," *University of Engineering and Technology Taxila. Technical Journal*, vol. 21, no. 2, pp. 96–106, 2016.
- [135] J. Cano-Izquierdo, J. Ibarrola, and M. Almonacid, "Improving motor imagery classification with a new BCI design using neuro-fuzzy S-dFasArt," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 20, no. 1, pp. 2–7, 2012.
- [136] G. Carpenter and S. Grossberg, *The handbook of brain theory and neural networks*, ch. Adaptive Resonance Theory. MIT Press, 2003.

- [137] Wikipedia, “ART (RNA).” [https://es.wikipedia.org/wiki/ART\\_\(RNA\)](https://es.wikipedia.org/wiki/ART_(RNA)).  
Accedido 2018-11-18.
- [138] G. Carpenter and S. Grossberg, “Art 3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures,” *Neural networks*, vol. 3, no. 2, pp. 129–152, 1990.
- [139] J. M. Cano-Izquierdo, Y. A. Dimitriadis, E. G. Sánchez, and J. L. Coronado, “Learning from noisy information in FasArt and FasBack neuro-fuzzy systems,” *Neural Networks*, vol. 14, no. 4, pp. 407 – 425, 2001.
- [140] J. Cano-Izquierdo, M. Almonacid, M. Pinzolas, and J. Ibarrola, “dFasArt: Dynamic neural processing in FasArt model,” *Neural Networks*, vol. 22, pp. 479–487, 2009.
- [141] R. Kohavi and G. H. John, “Wrappers for feature subset selection,” *Artificial intelligence*, vol. 97, no. 1-2, pp. 273–324, 1997.
- [142] J. Millan, M. Franze, J. Mourião, F. Cincotti, and F. Babiloni, “Relevant EEG features for the classification of spontaneous motor-related tasks,” *Biological Cybernetics*, vol. 86, no. 2, pp. 89–98, 2002.
- [143] R. Aler, I. Galvan, and J. Valls, “Applying evolution strategies to preprocessing EEG signals for brain-computer interfaces,” *Information Sciences*, vol. 215, pp. 53–66, 2012.
- [144] J. Yang, H. Singh, E. Hines, F. Schlaghecken, D. Iliescu, M. Leeson, and N. Stocks, “Channel selection and classification of eletroencephalogram signals: An artificial neural network and genetic algorithm-based approach,” *Artificial Intelligence in Medicine*, vol. 55, pp. 117–126, 2012.
- [145] L. He, Y. Hu, Y. Li, and D. Li, “Channel selection by Rayleigh coefficient maximization based genetic algorithm for classifying single-trial motor imagery EEG,” *Neurocomputing*, 2013.
- [146] A. Úbeda, E. Iáñez, J. M. Azorín, J. M. Sabater, and E. Fernández, “Classification method for BCIs based on the correlation of EEG maps,” *Neurocomputing*, vol. 114, pp. 98–106, 2013.
- [147] J. F. D. Saa and M. Cetin, “Discriminative methods for classification of asynchronous imaginary motor tasks from EEG data,” *IEEE transactions on neural systems and rehabilitation engineering*, vol. 21, no. 5, pp. 716–724, 2013.
- [148] Y. Wang, S. Gao, and X. Gao, “Common spatial pattern method for channel selection in motor imagery based brain-computer interface,” in *IEEE Engineering in Medicine and Biology 27th Annual Conference*, (Shangai, China), 2005.
- [149] S. Fazli, F. Popescu, M. Danóczy, B. Blankertz, K. Müller, and C. Grozea, “Subject-independent mental state classification in single trials,” *Neural Networks*, vol. 22, no. 9, pp. 1305–1312, 2009.

- [150] M. Arvaneh, C. Guan, K. Ang, and Q. C., “Optimizing the channel selection and clasification accuracy in EEG-based BCI,” *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 6, pp. 1865–1873, 2011.
- [151] M. Arvaneh, C. Guan, K. Ang, and C. Quek, “Robust EEG channel selection across sessions in brain-computer interface involving stroke patients,” in *Neural Networks (IJCNN), The 2012 International Joint Conference on*, pp. 1–6, IEEE, 2012.
- [152] A. Aghaei, M. Mahanta, and K. Plataniotis, “Separable common spatio-spectral patterns for motor imagery BCI systems,” *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 1, pp. 15–29, 2016.
- [153] D. Feess, M. Krell, and J. Metzen, “Comparison of sensor selection mechanisms for an ERP-based brain-computer interface,” *PloS one*, vol. 8, no. 7, p. e67543, 2013.
- [154] J. Decety and M. Lindgren, “Sensation of effort and duration of mentally executed actions,” *Scandinavian journal of psychology*, vol. 32, no. 2, pp. 97–104, 1991.
- [155] B. Blankertz, C. Sanelli, S. Halder, E. Hammer, A. Kübler, K. Müller, G. Curio, and T. Dickhaus, “Predicting BCI performance to study BCI illiteracy,” *BMC Neuroscience*, vol. 10, no. 1, 2009.
- [156] D. Tan and A. Nijholt, eds., *Brain-Computer Interfaces. Applying our Minds to Human-Computer Interaction*. Human-Computer Interaction Series, Springer, 2010.
- [157] J. d. R. Millán, F. Renkens, J. Mouriño, and W. Gerstner, “Brain-actuated interaction,” *Artificial Intelligence*, vol. 159, pp. 241–259, November 2004.
- [158] F. Galan, M. Nuttin, E. Lew, P. Ferrez, G. Vanacker, J. Philips, and J. Millan, “A brain-actuated wheelchair: Asynchronous and non-invasive brain-computer interfaces for continuous control of robots,” *Clinical Neurophysiology*, vol. 119, pp. 2159–2169, September 2008.
- [159] J. d. R. Millan, “On the need for on-line learning in brain-computer interfaces,” in *Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on*, vol. 4, pp. 2877–2882, IEEE, 2004.
- [160] J. Martinez-Leon, J. Cano-Izquierdo, and J. Ibarrola, “Are low cost brain computer interface headsets ready for motor imagery applications?,” *Expert Systems with Applications*, vol. 49, pp. 136–144, 2016.
- [161] B. Blankertz, F. Losch, M. Krauledat, G. Dornhege, G. Curio, and K. Müller, “The berlin brain-computer interface: Accurate performance from first-session in bci-naive subjects,” *IEEE Transactions on Biomedical Engineering*, vol. 55, pp. 2452–2462, October 2008.

- [162] J. Ekandem, T. Davis, I. Alvarez, M. James, and J. Gilbert, "Evaluating the ergonomics of BCI devices for research and experimentation," *Ergonomics*, vol. 55, no. 5, pp. 592–598, 2012.
- [163] D. Cernea, P. Olech, A. Ebert, and A. Kerren, "Measuring subjectivity," *KI-Künstliche Intelligenz*, vol. 26, no. 2, pp. 177–182, 2012.
- [164] J. Martinez-Leon, J. Cano-Izquierdo, and J. Ibarrola, "Feature selection applying statistical and neurofuzzy methods to EEG-based BCI," *Computational intelligence and neuroscience*, vol. 2015, p. 54, 2015.
- [165] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling," *IEEE Transaction on Fuzzy Systems*, vol. 1, pp. 7–31, February 1993.
- [166] M. S. Mahanta, A. S. Aghaei, and K. N. Plataniotis, "A Bayes optimal matrix-variate LDA for extraction of spatio-spectral features from EEG signals," in *Engineering in Medicine and Biology Society (EMBC), 2012 Annual International Conference of the IEEE*, pp. 3955–3958, IEEE, 2012.
- [167] T. Mullen, C. Kothe, Y. Chi, A. Ojeda, T. Kerth, S. Makeig, T. Jung, and G. Cauwenberghs, "Real-time neuroimaging and cognitive monitoring using wearable dry eeg," *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 11, pp. 2553–2567, 2015.
- [168] V. Nikulin, F. Hohlefeld, A. Jacobs, and G. Curio, "Quasi-movements: A novel motor–cognitive phenomenon," *Neuropsychologia*, vol. 46, no. 2, pp. 727–742, 2008.
- [169] R. Palaniappan, R. Paramesran, S. Nishida, and N. Saiwaki, "A new brain-computer interface design using fuzzy ARTMAP," *IEEE Transactions on neural systems and rehabilitation engineering*, vol. 10, no. 3, pp. 140–148, 2002.
- [170] C. K. Ho and M. Sasaki, "Mental tasks discrimination by neural networks with wavelet transform," *Microsystem technologies*, vol. 11, no. 8-10, pp. 933–942, 2005.





# Índice de Figuras

1.1. Representación gráfica del ciclo de vida de los avances tecnológicos desde su concepción hasta su adopción masiva [5] . . . . .	16
2.1. Estructura del Sistema Nervioso Central [8] . . . . .	20
2.2. Centros nerviosos del cerebro [13] . . . . .	21
2.3. Distribución de la médula espinal [14] . . . . .	23
2.4. Esquema general de un sistema BCI . . . . .	24
2.5. Relación entre la ubicación de los elementos sensores y las tecnologías para la captura de las señales cerebrales [6] . . . . .	25
2.6. Sistema BCI basado en MEG [24] . . . . .	27
2.7. Sistemas BCI de captura de datos no invasivos . . . . .	28
2.8. Sistema BCI basado en tecnología EEG [28] . . . . .	29
2.9. Ubicaciones estándar de los elementos sensores según se define en el Sistema 10-20 [29] . . . . .	29
2.10. Gama de amplificadores comercializados por Brain Products [47] . . . . .	33
2.11. Biosemi Active Two en una configuración de 128 canales [28] . . . . .	34
2.12. ANT Neuro eego mylab en una configuración de 128 canales [48] . . . . .	35
2.13. Amplificador g.tec Hlamp [49] . . . . .	35
2.14. NeuroElectrics Enobio en una configuración de 32 canales [50] . . . . .	36
2.15. NeuroSky MindWave [51] . . . . .	38
2.16. Dispositivos de captura de datos EEG Emotiv [52] . . . . .	38
2.17. Ultracortex Mark IV [53] . . . . .	39
2.18. Placas de procesamiento de datos Open BCI [53] . . . . .	39
2.19. Interaxon Muse [54] . . . . .	40
2.20. Posición de los sensores del Emotiv EPOC en el sistema internacional 10-20	41
2.21. Panel de Control Emotiv EPOC . . . . .	42
2.22. Test Bench Emotiv EPOC . . . . .	43
2.23. Panel de Control - Expresiv Suite . . . . .	44
2.24. Panel de Control - Affectiv Suite . . . . .	46
2.25. Panel de Control - Cognitiv Suite . . . . .	48
2.26. Prótesis de rehabilitación integrada con Emotiv EPOC [84] . . . . .	50
2.27. Integración de Emotiv EPOC con un teléfono móvil. NeuroPhone [92] . . .	51
2.28. Silla de ruedas controlada utilizando Emotiv EPOC [98] . . . . .	54

2.29. Usuario utilizando el sistema híbrido Emotiv EPOC EasyCap . . . . .	57
2.30. BCI Competition III Dataset V. Datos preprocesados: posiciones coloreadas en verde. Datos raw: todas las posiciones coloreadas (verde + azul) . . . . .	59
2.31. Espectro de la señal comparando imaginación de movimiento izquierda y derecha en raw y después de aplicar algoritmos de filtrado mejora de la señal [124] . . . . .	62
2.32. Estructura fundamental de una red de tipo ART [137] . . . . .	65
2.33. Arquitectura del modelo S-dFasArt [135] . . . . .	67
2.34. Función de activación/pertenencia para cada nodo $A^j$ del nivel de entrada en el modelo S-dFasArt [135] . . . . .	68
2.35. Arquitectura del sistema S-dFasArt utilizado . . . . .	69
3.1. Interfaz gráfico de la aplicación de captura de datos . . . . .	76
3.2. Posición de los usuarios en la captura de datos utilizando Emotiv EPOC . .	79
3.3. Distribución de las respuestas de los usuarios a las preguntas de los bloques 2 y 3 del cuestionario realizado después del experimento. La letra B distingue el bloque de preguntas del cuestionario y la Q a la pregunta . . . . .	81
3.4. Comparación entre las ventanas de Hamming y Hanning . . . . .	83
3.5. Restricciones relacionadas con la cantidad datos máxima para proveer de una salida en el BCI Competition III dataset V aplicadas a los datos capturados Emotiv EPOC . . . . .	84
3.6. Proceso de búsqueda de los valores óptimos de los parámetros $\sigma$ y $A_t$ de los modelos S-dFasArt . . . . .	86
3.7. Distribución de las confusiones para las tareas motoras Izquierda - $I$ y Derecha - $D$ . Datos EmoExt . . . . .	97
3.8. Distribución de las confusiones para la tarea Palabra - $P$ . Datos EmoExt .	97
3.9. Representación gráfica de los resultados de la clasificación en función del la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra - $P$ . . . . .	98
3.10. Interfaz gráfico de la aplicación de captura de datos con realimentación . .	102
3.11. Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos BCIComp vs BCIEpoc .	105
3.12. Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos EasyBCI vs EasyEpoc .	107
3.13. Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos BCIComp vs EasyBCI .	110
3.14. Variación del el acierto de clasificación para las tareas Izquierda - $I$ y Derecha - $D$ en valor absoluto. Datos BCIComp vs EasyBCI . . . . .	110
3.15. Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos BCIEpoc vs EasyEpoc .	112
3.16. Variación entre el acierto de clasificación para las tareas Izquierda - $I$ y Derecha - $D$ en valor absoluto. Datos BCIEpoc vs EasyEpoc . . . . .	113
3.17. Valor medio de la señal medida por cada sensor (a) Emotiv EPOC. Valor medio: $4,3602e + 003$ . (b) Emotiv EasyCap, Valor medio: $4,1132e + 003$ . .	115

3.18. Varianza de la señal medida por cada sensor (a) Emotiv EPOC. Valor medio: $1,5206e + 003$ . (b) Emotiv EasyCap, Valor medio: $2,5837e + 003$ . . . . .	115
3.19. Comparación gráfica de la precisión alcanzada en la predicción de cada tarea. Comparativa por sujetos y en media. Datos EmoEpoc, BCIEpoc y EasyEpoc . . . . .	117
3.20. Variación en el acierto de clasificación para las tareas Izquierda - $I$ y Derecha - $D$ en valor absoluto. Diferentes conjuntos de datos en posiciones Emotiv .	117
3.21. Comparativa del acierto medio de clasificación para las diferentes tareas. Datos EmoEpoc, BCIEpoc, EasyEpoc y EasyBCI . . . . .	119
3.22. Comparativa del acierto medio de clasificación para las diferentes tareas. Datos EmoEpoc, BCIEpoc y EasyEpoc . . . . .	120
4.1. Proceso de creación de la arquitectura S-dFasArt . . . . .	127
4.2. Generación de un modelo individual $s_i s_j s_k$ en la arquitectura S-dFasArt siendo $s_i$ , $s_j$ y $s_k$ los conjuntos de datos de entrenamiento . . . . .	128
4.3. Valores $J(x_j)$ calculados utilizando el método estadístico de selección de características. El valor $(1/C)^C$ queda representado por la línea continua. Datos BCIComp . . . . .	131
4.4. Representación de la relevancia de cada componente atendiendo a la puntuación obtenida en base a su carácter discriminante. Método estadístico. Datos BCIComp . . . . .	131
4.5. Valores $F(x_j)$ calculados utilizando el criterio difuso para los tres usuarios utilizando la sesión 1 como entrenamiento y la 2 para el ajuste de parámetros y la poda de reglas. Datos BCIComp . . . . .	135
4.6. Representación de la relevancia de cada componente atendiendo a la puntuación obtenida en base a su carácter discriminante. Criterio difuso. Datos BCIComp . . . . .	135
4.7. BCIEpoc Sujeto 1 - Distribución espectral de potencia en las posiciones Emotiv EPOC . . . . .	142
4.8. EasyBCI Sujeto 1 - Distribución de potencia por tarea para la posición C4 .	151
4.9. BCIEpoc Sujeto 1 - Comparativa de la distribución espectral de potencia en función de los canales seleccionados . . . . .	154
4.10. Número de características por cada punto de la tasa de acierto . . . . .	161
4.11. Características comunes en los modelos en función del número de sujetos para los que aparecen . . . . .	162
4.12. Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios . . . . .	162
4.13. Niveles de acierto alcanzados seleccionando conjuntos comunes de características utilizando una selección de características basada en el criterio difuso y una selección por orden . . . . .	163
4.14. Sujeto 1 - Modelo simplificado de tres reglas. Datos BCI Comp . . . . .	169
4.15. Número de características medio requerido por cada combinación de la metodología de selección de características presentada . . . . .	174

- B.1. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIComp. Sujeto 1. Diferentes  $A_r$  . . . . . 224
- B.2. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIComp. Sujeto 2. Diferentes  $A_r$  . . . . . 225
- B.3. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIComp. Sujeto 3. Diferentes  $A_r$  . . . . . 226
  
- C.1. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIEpoc. Sujeto 1. Diferentes  $A_r$  . . . . . 228
- C.2. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIEpoc. Sujeto 2. Diferentes  $A_r$  . . . . . 229
- C.3. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIEpoc. Sujeto 3. Diferentes  $A_r$  . . . . . 230
  
- D.1. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoEpoc. Sujeto 1. Diferentes  $A_r$  . . . . . 232
- D.2. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoEpoc. Sujeto 2. Diferentes  $A_r$  . . . . . 233
- D.3. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoEpoc. Sujeto 3. Diferentes  $A_r$  . . . . . 234
  
- E.1. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EasyBCI. Sujeto 1. Diferentes  $A_r$  . . . . . 236
- E.2. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EasyBCI. Sujeto 2. Diferentes  $A_r$  . . . . . 237
- E.3. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EasyBCI. Sujeto 3. Diferentes  $A_r$  . . . . . 238
  
- F.1. Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EasyEpoc. Sujeto 1. Diferentes  $A_r$  . . . . . 240

F.2.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EasyEpoc. Sujeto 2. Diferenes $A_r$ . . . . .	241
F.3.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EasyEpoc. Sujeto 3. Diferenes $A_r$ . . . . .	242
G.1.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 1. Diferentes $A_r$ . . . . .	244
G.2.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 2. Diferentes $A_r$ . . . . .	245
G.3.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 3. Diferentes $A_r$ . . . . .	246
G.4.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 4. Diferentes $A_r$ . . . . .	247
G.5.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 5. Diferentes $A_r$ . . . . .	248
G.6.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 6. Diferentes $A_r$ . . . . .	249
G.7.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 7. Diferentes $A_r$ . . . . .	250
G.8.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 8. Diferentes $A_r$ . . . . .	251
G.9.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 9. Diferentes $A_r$ . . . . .	252
G.10.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 10. Diferentes $A_r$ . . . . .	253
G.11.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 11. Diferentes $A_r$ . . . . .	254
G.12.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 12. Diferentes $A_r$ . . . . .	255

H.1.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 1. Diferentes PSD . . . . .	258
H.2.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 2. Diferentes PSD . . . . .	260
H.3.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 3. Diferentes PSD . . . . .	262
H.4.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 4. Diferentes PSD . . . . .	264
H.5.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 5. Diferentes PSD . . . . .	266
H.6.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 6. Diferentes PSD . . . . .	268
H.7.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 7. Diferentes PSD . . . . .	270
H.8.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 8. Diferentes PSD . . . . .	272
H.9.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 9. Diferentes PSD . . . . .	274
H.10.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 10. Diferentes PSD . . . . .	276
H.11.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 11. Diferentes PSD . . . . .	278
H.12.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos EmoExt. Sujeto 12. Diferentes PSD . . . . .	280
I.1.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos Prueba 1 realimentación . . . . .	284
I.2.	Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - $I$ , 5 representa Derecha - $D$ y 7 representa Palabra $P$ . Datos Prueba 2 realimentación . . . . .	286

J.1.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos BCIComp. Sujeto 1 . . . . .	290
J.2.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos BCIComp. Sujeto 2 . . . . .	291
J.3.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos BCIComp. Sujeto 3 . . . . .	292
K.1.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos BCIEpoc. Sujeto 1 . . . . .	294
K.2.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos BCIEpoc. Sujeto 2 . . . . .	295
K.3.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos BCIEpoc. Sujeto 3 . . . . .	296
L.1.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoEpoc. Sujeto 1 . . . . .	298
L.2.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoEpoc. Sujeto 2 . . . . .	299
L.3.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoEpoc. Sujeto 3 . . . . .	300
M.1.	Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EasyBCI. Sujeto 1 . . . . .	302

M.2. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EasyBCI. Sujeto 2 . . . . .	303
M.3. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EasyBCI. Sujeto 3 . . . . .	304
N.1. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EasyEpoc. Sujeto 1 . . . . .	306
N.2. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EasyEpoc. Sujeto 2 . . . . .	307
N.3. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EasyEpoc. Sujeto 3 . . . . .	308
Ñ.1. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 1 . . . . .	310
Ñ.2. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 2 . . . . .	311
Ñ.3. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 3 . . . . .	312
Ñ.4. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 4 . . . . .	313
Ñ.5. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 5 . . . . .	314



Ñ.6. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 6 . . . . .	315
Ñ.7. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 7 . . . . .	316
Ñ.8. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 8 . . . . .	317
Ñ.9. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 9 . . . . .	318
Ñ.10. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 10 . . . . .	319
Ñ.11. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 11 . . . . .	320
Ñ.12. Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - <i>I</i> , 5 representa Derecha - <i>D</i> y 7 representa Palabra <i>P</i> . Datos EmoExt. Sujeto 12 . . . . .	321



# Índice de Tablas

2.1. Dispositivos de captura de datos EEG profesionales . . . . .	33
2.2. Dispositivos de captura de datos EEG de bajo coste . . . . .	37
2.3. Resumen de las características de las aplicaciones desarrolladas con Emotiv utilizando Expresiv Suite . . . . .	45
2.4. Resumen de las características de las aplicaciones desarrolladas con Emotiv utilizando Affectiv Suite . . . . .	47
2.5. Resumen de las características de las aplicaciones desarrolladas con Emotiv utilizando Cognitiv Suite . . . . .	49
2.6. Resumen de las características de las aplicaciones desarrolladas con Emotiv sin utilizar algoritmos disponibles en el Panel de Control . . . . .	52
2.7. Diferentes aplicaciones desarrolladas utilizando Emotiv EPOC publicadas en revistas de investigación desde 2017 . . . . .	53
2.8. Publicaciones evaluando la calidad de los datos capturados con Emotiv EPOC tomando como referencia los obtenidos por equipos EEG de investi- gación . . . . .	56
2.9. Historia de las BCI Competition en Números: número de conjuntos de datos provistos, número de presentaciones recibidas y número de laboratorios de investigación que participaron presentando soluciones [122, 123] . . . . .	58
2.10. Algoritmos de clasificación que han alcanzado una mayor precisión para el BCI Competition III dataset V . . . . .	63
2.11. Algoritmos de selección de características que han alcanzado una mayor pre- cisión para los datos BCI Competition III dataset V . . . . .	73
3.1. Nomenclatura definida para los conjuntos de datos utilizados en esta tesis doctoral . . . . .	77
3.2. Definición de los valores de $\sigma$ y $A_t$ calculados en cada iteración del algoritmo de búsqueda de parámetros óptimos para el clasificador S-dFasArt . . . . .	87
3.3. Niveles de precisión alcanzados para los datos preprocesados BCI Compe- tition III dataset V mostrados como % . . . . .	88
3.4. Matriz de confusión para los datos preprocesados BCI Competition III da- taset V . . . . .	89

3.5. Niveles de precisión alcanzados para los datos BCI Competition III dataset V seleccionando las posiciones disponibles en Emotiv EPOC mostrados como % . . . . .	89
3.6. Matriz de confusión para los datos BCI Competition III dataset V seleccionando las posiciones disponibles en Emotiv EPOC . . . . .	90
3.7. Niveles de precisión alcanzados para los datos capturados con Emotiv EPOC mostrados como % . . . . .	91
3.8. Matriz de confusión para los datos capturados con Emotiv EPOC . . . . .	91
3.9. Niveles de precisión alcanzados para los datos capturados con Emotiv EasyCap en las posiciones de los datos preprocesados del BCI Competition mostrados como % . . . . .	92
3.10. Matriz de confusión para los datos capturados con Emotiv EPOC EasyCap en las posiciones de los datos preprocesados del BCI Competition . . . . .	93
3.11. Niveles de precisión alcanzados para los datos capturados con Emotiv EPOC EasyCap en las posiciones estándar Emotiv EPOC mostrados como % . . . . .	94
3.12. Matriz de confusión para los datos capturados con Emotiv EPOC EasyCap en las posiciones de los datos preprocesados del BCI Competition . . . . .	94
3.13. Niveles de precisión alcanzados para los datos capturados con Emotiv EPOC de la base de datos extendida mostrados como %. En verde, naranja y rojo destacan los usuarios para los que se alcanzaron precisiones por encima del 60 %, entre el 50 % y el 60 % y menores al 50 % respectivamente. En azul se resalta la tarea mejor predicha. En magenta se muestra el acierto mínimo y medio de la tarea motora, mientras que en azul claro se han señalado las tasas de medias de acierto para las tareas Derecha - <i>D</i> e Izquierda - <i>I</i> y en violeta la media de la diferencia en el acierto de los estados motores . . . . .	95
3.14. Niveles de precisión alcanzados por los 5 mejores usuarios de la base de datos extendida Emotiv EPOC mostrados como %. En azul se distingue la tarea cuya predicción alcanzó un acierto mayor para cada sujeto, en magenta se muestra el acierto mínimo y medio de la tarea motora, mientras que en violeta la media de la diferencia en el acierto de los estados motores . . . . .	96
3.15. Niveles de precisión alcanzados utilizando datos capturados con Emotiv EPOC de la base de datos extendida mostrados como % - Valor de $A_r$ que maximiza el resultado. Los resultados en verde destacan a los usuarios cuyos datos se han procesado con $A_r = 0.001$ , los de color azul muestran aquellos procesados con $A_r = 0.002$ y los resaltados en violeta a los basados en $A_r = 0.003$ . . . . .	99

3.16. Niveles de precisión alcanzados utilizando datos capturados con Emotiv EPOC de la base de datos extendida mostrados como % utilizando $A_r=0.002$ . Los sujetos en <b>naranja</b> son aquéllos cuya precisión varía respecto a la original. En <b>verde</b> destacan los usuarios que ascienden en el ranking y en <b>rojo</b> los que descienden. En <b>azul</b> se resalta la tarea mejor predicha. En <b>magenta</b> se muestra el acierto mínimo y medio de la tarea motora, mientras que en <b>azul claro</b> se han señalado las tasas de medias de acierto para las tareas Derecha - $D$ e Izquierda - $I$ y en <b>violeta</b> la media de la diferencia en el acierto de los estados motores . . . . .	100
3.17. Niveles de precisión alcanzados aplicando diferentes aproximaciones al procesamiento de la PSD. Se utilizan datos capturados con Emotiv EPOC de la base de datos extendida y un valor de $A_r = 0.002$ . Para cada sujeto se ha marcado el valor máximo de precisión en <b>verde</b> y el segundo mayor en <b>naranja</b>	101
3.18. Datos capturados con Emotiv EPOC. Pruebas con realimentación. Comparativa basada en la tasa de acierto en % . . . . .	103
3.19. Datos preprocesados BCI Competition III dataset V (BCIComp) vs BCI Competition III dataset V canales Emotiv (BCIEpoc). Comparativa basada en la tasa de acierto en % . . . . .	104
3.20. Datos preprocesados BCI Competition III dataset V (BCIComp) vs BCI Competition III dataset V canales Emotiv (BCIEpoc). Comparativa basada en la tasa media de acierto en % . . . . .	105
3.21. Datos preprocesados Emotiv EasyCap posiciones BCI (EasyBCI) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa de acierto en % . . . . .	106
3.22. Datos preprocesados BCI Competition III dataset V (BCIComp) vs BCI Competition III dataset V canales Emotiv (BCIEpoc). Comparativa basada en la tasa media de acierto en % . . . . .	106
3.23. Datos preprocesados BCI Competition III dataset V (BCIComp) vs Emotiv EasyCap posiciones BCI (EasyBCI). Comparativa basada en la tasa de acierto en % . . . . .	109
3.24. Datos preprocesados BCI Competition III dataset V (BCIComp) vs Emotiv EasyCap posiciones BCI (EasyBCI). Comparativa basada en la tasa media de acierto en % . . . . .	109
3.25. Datos preprocesados BCI Competition III dataset V en las posiciones Emotiv (BCIEpoc) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa de acierto en % . . . . .	111
3.26. Datos preprocesados BCI Competition III dataset V (BCIComp) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa media de acierto en % . . . . .	111
3.27. BCI Competition III dataset V canales Emotiv (BCIEpoc) vs Datos capturados con Emotiv EPOC (EmoEpoc). Comparativa basada en la tasa de acierto en % [160] . . . . .	114

3.28. BCI Competition III dataset V canales Emotiv (BCIEpoc) vs Datos capturados con Emotiv EPOC (EmoEpoc). Comparativa basada en la tasa media de acierto en % [160] . . . . .	114
3.29. Datos Emotiv EPOC (EmoEpoc) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa de acierto en % . . . . .	116
3.30. Datos Emotiv EPOC (EmoEpoc) vs Emotiv EasyCap posiciones EPOC (EasyEpoc). Comparativa basada en la tasa media de acierto en % . . . . .	116
3.31. Datos Emotiv EPOC (EmoEpoc) vs Datos Emotiv EPOC Ext (EmoExt). Comparativa basada en la tasa media de acierto en % . . . . .	118
4.1. Nomenclatura definida para los conjuntos de datos utilizados en esta tesis doctoral . . . . .	129
4.2. Canal y frecuencia asociadas a cada característica del vector de entrada - Datos en posiciones BCI Competition . . . . .	130
4.3. Canal y frecuencia asociadas a cada característica del vector de entrada - Datos en posiciones Emotiv EPOC . . . . .	130
4.4. Características más relevantes para cada usuario utilizando el método estadístico. Datos BCIComp . . . . .	132
4.5. Tasa de acierto (en %) para el Sujeto 1 en función de la dimensión del vector de entrada (M) aplicando el método estadístico y la selección por orden. $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp . . . . .	132
4.6. Tasa de acierto (en %) para el Sujeto 2 en función de la dimensión del vector de entrada (M) aplicando el método estadístico y la selección por orden. $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp . . . . .	133
4.7. Tasa de acierto (en %) para el Sujeto 3 en función de la dimensión del vector de entrada (M) aplicando el método estadístico y la selección por orden. $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp . . . . .	133
4.8. Características y valores RC para los diferentes usuarios basados en una selección GMDH para datos puntuados utilizando el método estadístico. Datos BCIComp . . . . .	134
4.9. Características más relevantes para cada usuario utilizando el criterio difuso. Se definen como $C_f$ donde C representa al canal y $f$ es la banda de frecuencia seleccionada. Datos BCIComp . . . . .	136
4.10. Tasa de acierto (en %) para el Sujeto 1 en función de la dimensión del vector de entrada (M) aplicando el criterio difuso y la selección por orden. $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp . . . . .	136
4.11. Tasa de acierto (en %) para el Sujeto 2 en función de la dimensión del vector de entrada (M) aplicando el criterio difuso y la selección por orden. $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp . . . . .	137

4.12. Tasa de acierto (en %) para el Sujeto 3 en función de la dimensión del vector de entrada (M) aplicando el criterio difuso y la selección por orden. $s_i s_j s_k$ : i sesión de aprendizaje, j sesión para la poda de reglas, k sesión de test. Datos BCIComp . . . . .	137
4.13. Características y valores de RC para los modelos calculados de los diferentes usuarios basado en selección GMDH para datos puntuados basados en el criterio difuso. Datos BCIComp . . . . .	138
4.14. Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos BCIComp . . . . .	139
4.15. Canales y frecuencias seleccionadas aplicando el criterio difuso + GMDH. Se denotan como $\odot$ aquellas características seleccionadas por un sujeto, como $\oslash$ las seleccionadas por dos y como $\otimes$ las seleccionadas por todos ellos. Datos BCIComp . . . . .	139
4.16. Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos preprocesados BCI Competition III dataset V mostrados como % . . . . .	141
4.17. Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos BCIEpoc . . . . .	143
4.18. Canales y frecuencias seleccionadas aplicando el método estadístico + GMDH. Se denotan como $\odot$ aquellas características seleccionadas por un sujeto, como $\oslash$ las seleccionadas por dos y como $\otimes$ las seleccionadas por todos ellos. Datos BCIEpoc . . . . .	144
4.19. Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos BCI Competition III dataset V seleccionando las posiciones disponibles en Emotiv EPOC mostrados como % . . . . .	145
4.20. Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos EmoEpoc . . . . .	146
4.21. Canales y frecuencias seleccionadas aplicando el criterio difuso + selección por orden. Se denotan como $\odot$ aquellas características seleccionadas por un sujeto, como $\oslash$ las seleccionadas por dos y como $\otimes$ las seleccionadas por todos ellos. Datos EmoEpoc . . . . .	147
4.22. Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos capturados con Emotiv EPOC mostrados como % . . . . .	148
4.23. Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos EasyBCI . . . . .	150
4.24. Canales y frecuencias seleccionadas aplicando el criterio difuso + GMDH. Se denotan como $\odot$ aquellas características seleccionadas por un sujeto, como $\oslash$ las seleccionadas por dos y como $\otimes$ las seleccionadas por todos ellos. Datos EasyBCI . . . . .	152
4.25. Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los capturados Emotiv EasyCap en las posiciones de los datos preprocesados del BCI Competition mostrados como % . . . . .	152

- 4.26. Resultado de la evaluación de los conjuntos de características seleccionados sobre la sesión de test. Datos EasyEpoc . . . . . 155
- 4.27. Canales y frecuencias seleccionadas aplicando criterio difuso + GMDH. Se denotan como  $\odot$  aquéllas características seleccionadas por un sujeto, como  $\oslash$  las seleccionadas por dos y como  $\otimes$  las seleccionadas por todos ellos. Datos EasyEpoc . . . . . 156
- 4.28. Niveles de precisión alcanzados por tarea aplicando la metodología de selección de características para los datos capturados con Emotiv EasyCap en las posiciones estándar Emotiv EPOC mostrados como % . . . . . 157
- 4.29. Conjuntos de características seleccionados para el método estadístico y selección por orden. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt . . . . . 158
- 4.30. Conjuntos de características seleccionados para el método estadístico y selección GMDH. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt . . . . . 158
- 4.31. Conjuntos de características seleccionados para el criterio difuso y selección por orden. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt . . . . . 159
- 4.32. Conjuntos de características seleccionados para el criterio difuso y selección por orden. Se destacan en negrita los mejores resultados para cada usuario y en azul todos los casos en los que la aproximación superó el rendimiento alcanzado utilizando el total de las características. Datos EmoExt . . . . . 160
- 4.33. Canales y frecuencias seleccionadas aplicando el método estadístico + selección por orden para características comunes entre sujetos. Se denotan como  $\odot$  aquéllas características seleccionadas para al menos un sujeto, como  $\oslash$  las seleccionadas por al menos dos y como  $\otimes$  las seleccionadas por al menos tres ellos. Datos EmoExt . . . . . 164
- 4.34. Canales y frecuencias seleccionadas aplicando el método estadístico + selección GMDH para características comunes entre sujetos. Se denotan como  $\odot$  aquéllas características seleccionadas para al menos un sujeto, como  $\oslash$  las seleccionadas por al menos dos y como  $\otimes$  las seleccionadas por al menos tres ellos. Datos EmoExt . . . . . 165
- 4.35. Canales y frecuencias seleccionadas aplicando el criterio difuso + selección por orden para características comunes entre sujetos. Se denotan como  $\odot$  aquéllas características seleccionadas para al menos un sujeto, como  $\oslash$  las seleccionadas por al menos dos y como  $\otimes$  las seleccionadas por al menos tres ellos. Datos EmoExt . . . . . 165



4.36. Canales y frecuencias seleccionadas aplicando el criterio difuso + selección GMDH para características comunes entre sujetos. Se denotan como $\odot$ aquéllas características seleccionadas para al menos un sujeto, como $\oslash$ las seleccionadas por al menos dos y como $\otimes$ las seleccionadas por al menos tres ellos. Datos EmoExt . . . . .	166
4.37. Comparación de la precisión alcanzada para los datos preprocesados BCI Competition III dataset V entre la metodología propuesta y las mejores propuestas de la literatura. Se incluye el modelo unificado. Se denotan con * las aportaciones propias . . . . .	167
4.38. Niveles de precisión alcanzados por tarea para el modelo unificado en comparación con los niveles alcanzados para los datos preprocesados BCI Competition III dataset V mostrados como % . . . . .	167
4.39. Resultados de predicción de la sesión de test para cada uno de los módulos clasificadores individuales S-dFasArt del modelo unificado. (Notación: $s_x s_y s_z$ = Sujeto: x, Sesión para aprendizaje: y, Sesión para el ajuste-poda: z). Datos BCIComp . . . . .	168
4.40. Sujeto 1- Matriz de confusión para los datos preprocesados BCI Competition III dataset V en las características del modelo unificado . . . . .	170
4.41. Comparación de la precisión alcanzada para los datos preprocesados BCI Competition III dataset V entre la metodología propuesta y las mejores alternativas existentes en la literatura . . . . .	171
4.42. Niveles de acierto alcanzados por los sujetos de las diferentes bases de datos después de aplicar la metodología de selección de características. Se resaltan en azul los niveles de precisión que superaron a los iniciales . . . . .	172
B.1. Datos preprocesados BCI Competition III dataset V. Comparativa acierto entre usuarios. Tasa de acierto en % . . . . .	223
B.2. Niveles de precisión alcanzados para los datos BCIComp Sujeto 1 para diferentes valores de $A_r$ mostrados como % . . . . .	224
B.3. Matriz de confusión para los datos BCIComp Sujeto 1 para diferentes valores de $A_r$ . . . . .	224
B.4. Niveles de precisión alcanzados para los datos BCIComp Sujeto 2 para diferentes valores de $A_r$ mostrados como % . . . . .	225
B.5. Matriz de confusión para los datos BCIComp Sujeto 2 para diferentes valores de $A_r$ . . . . .	225
B.6. Niveles de precisión alcanzados para los datos BCIComp Sujeto 3 para diferentes valores de $A_r$ mostrados como % . . . . .	226
B.7. Matriz de confusión para los datos BCIComp Sujeto 3 para diferentes valores de $A_r$ . . . . .	226
C.1. Datos BCI Competition - Posiciones Emotiv. Comparativa acierto entre usuarios. Tasa de acierto en % . . . . .	227
C.2. Niveles de precisión alcanzados para los datos BCIEpoc Sujeto 1 para diferentes valores de $A_r$ mostrados como % . . . . .	228

C.3. Matriz de confusión para los datos BCIEpoc Sujeto 1 para diferentes valores de $A_r$ . . . . .	228
C.4. Niveles de precisión alcanzados para los datos BCIEpoc Sujeto 2 para diferentes valores de $A_r$ mostrados como % . . . . .	229
C.5. Matriz de confusión para los datos BCIEpoc Sujeto 2 para diferentes valores de $A_r$ . . . . .	229
C.6. Niveles de precisión alcanzados para los datos BCIEpoc Sujeto 3 para diferentes valores de $A_r$ mostrados como % . . . . .	230
C.7. Matriz de confusión para los datos BCIEpoc Sujeto 3 para diferentes valores de $A_r$ . . . . .	230
D.1. Datos capturados con Emotiv EPOC. Comparativa acierto entre usuarios. Tasa de acierto en % . . . . .	231
D.2. Niveles de precisión alcanzados para los datos EmoEpoc Sujeto 1 para diferentes valores de $A_r$ mostrados como % . . . . .	232
D.3. Matriz de confusión para los datos EmoEpoc Sujeto 1 para diferentes valores de $A_r$ . . . . .	232
D.4. Niveles de precisión alcanzados para los datos EmoEpoc Sujeto 2 para diferentes valores de $A_r$ mostrados como % . . . . .	233
D.5. Matriz de confusión para los datos EmoEpoc Sujeto 2 para diferentes valores de $A_r$ . . . . .	233
D.6. Niveles de precisión alcanzados para los datos EmoEpoc Sujeto 3 para diferentes valores de $A_r$ mostrados como % . . . . .	234
D.7. Matriz de confusión para los datos EmoEpoc Sujeto 3 para diferentes valores de $A_r$ . . . . .	234
E.1. Datos capturados con Emotiv EasyCap - Posiciones BCI Competition. Comparativa acierto entre usuarios. Tasa de acierto en % . . . . .	235
E.2. Niveles de precisión alcanzados para los datos EasyBCI Sujeto 1 para diferentes valores de $A_r$ mostrados como % . . . . .	236
E.3. Matriz de confusión para los datos EasyBCI Sujeto 1 para diferentes valores de $A_r$ . . . . .	236
E.4. Niveles de precisión alcanzados para los datos EasyBCI Sujeto 2 para diferentes valores de $A_r$ mostrados como % . . . . .	237
E.5. Matriz de confusión para los datos EasyBCI Sujeto 2 para diferentes valores de $A_r$ . . . . .	237
E.6. Niveles de precisión alcanzados para los datos EasyBCI Sujeto 3 para diferentes valores de $A_r$ mostrados como % . . . . .	238
E.7. Matriz de confusión para los datos EasyBCI Sujeto 3 para diferentes valores de $A_r$ . . . . .	238
F.1. Datos capturados con Emotiv EasyCap - Posiciones Emotiv EPOC. Comparativa acierto entre usuarios. Tasa de acierto en % . . . . .	239

F.2. Niveles de precisión alcanzados para los datos EasyEpoc Sujeto 1 para diferentes valores de $A_r$ mostrados como % . . . . .	240
F.3. Matriz de confusión para los datos EasyEpoc Sujeto 1 para diferentes valores de $A_r$ . . . . .	240
F.4. Niveles de precisión alcanzados para los datos EasyEpoc Sujeto 2 para diferentes valores de $A_r$ mostrados como % . . . . .	241
F.5. Matriz de confusión para los datos EasyEpoc Sujeto 2 para diferentes valores de $A_r$ . . . . .	241
F.6. Niveles de precisión alcanzados para los datos EasyEpoc Sujeto 3 para diferentes valores de $A_r$ mostrados como % . . . . .	242
F.7. Matriz de confusión para los datos EasyEpoc Sujeto 3 para diferentes valores de $A_r$ . . . . .	242
G.1. Datos capturados con Emotiv EPOC. Base de datos Extendida. Comparativa acierto entre usuarios. Tasa de acierto en % . . . . .	243
G.2. Niveles de precisión alcanzados para los datos EmoExt Sujeto 1 para diferentes valores de $A_r$ mostrados como % . . . . .	244
G.3. Matriz de confusión para los datos EmoExt Sujeto 1 para diferentes valores de $A_r$ . . . . .	244
G.4. Niveles de precisión alcanzados para los datos EmoExt Sujeto 2 para diferentes valores de $A_r$ mostrados como % . . . . .	245
G.5. Matriz de confusión para los datos EmoExt Sujeto 2 para diferentes valores de $A_r$ . . . . .	245
G.6. Niveles de precisión alcanzados para los datos EmoExt Sujeto 3 para diferentes valores de $A_r$ mostrados como % . . . . .	246
G.7. Matriz de confusión para los datos EmoExt Sujeto 3 para diferentes valores de $A_r$ . . . . .	246
G.8. Niveles de precisión alcanzados para los datos EmoExt Sujeto 4 para diferentes valores de $A_r$ mostrados como % . . . . .	247
G.9. Matriz de confusión para los datos EmoExt Sujeto 4 para diferentes valores de $A_r$ . . . . .	247
G.10. Niveles de precisión alcanzados para los datos EmoExt Sujeto 5 para diferentes valores de $A_r$ mostrados como % . . . . .	248
G.11. Matriz de confusión para los datos EmoExt Sujeto 5 para diferentes valores de $A_r$ . . . . .	248
G.12. Niveles de precisión alcanzados para los datos EmoExt Sujeto 6 para diferentes valores de $A_r$ mostrados como % . . . . .	249
G.13. Matriz de confusión para los datos EmoExt Sujeto 6 para diferentes valores de $A_r$ . . . . .	249
G.14. Niveles de precisión alcanzados para los datos EmoExt Sujeto 7 para diferentes valores de $A_r$ mostrados como % . . . . .	250
G.15. Matriz de confusión para los datos EmoExt Sujeto 7 para diferentes valores de $A_r$ . . . . .	250

G.16.Niveles de precisión alcanzados para los datos EmoExt Sujeto 8 para diferentes valores de $A_r$ mostrados como % . . . . .	251
G.17.Matriz de confusión para los datos EmoExt Sujeto 8 para diferentes valores de $A_r$ . . . . .	251
G.18.Niveles de precisión alcanzados para los datos EmoExt Sujeto 9 para diferentes valores de $A_r$ mostrados como % . . . . .	252
G.19.Matriz de confusión para los datos EmoExt Sujeto 9 para diferentes valores de $A_r$ . . . . .	252
G.20.Niveles de precisión alcanzados para los datos EmoExt Sujeto 10 para diferentes valores de $A_r$ mostrados como % . . . . .	253
G.21.Matriz de confusión para los datos EmoExt Sujeto 10 para diferentes valores de $A_r$ . . . . .	253
G.22.Niveles de precisión alcanzados para los datos EmoExt Sujeto 11 para diferentes valores de $A_r$ mostrados como % . . . . .	254
G.23.Matriz de confusión para los datos EmoExt Sujeto 11 para diferentes valores de $A_r$ . . . . .	254
G.24.Niveles de precisión alcanzados para los datos EmoExt Sujeto 12 para diferentes valores de $A_r$ mostrados como % . . . . .	255
G.25.Matriz de confusión para los datos EmoExt Sujeto 12 para diferentes valores de $A_r$ . . . . .	255
H.1. Datos capturados con Emotiv EPOC. Base de datos Extendida. Comparativa acierto entre usuarios y algoritmos de cálculo de la PSD. $A_r=0.002$ . Tasa de acierto en % . . . . .	257
H.2. Niveles de precisión alcanzados para los datos EmoExt Sujeto 1 para diferentes variantes del cálculo de la PSD mostrados como % . . . . .	258
H.3. Matriz de confusión para los datos EmoExt Sujeto 1 para diferentes variantes del cálculo de la de PSD . . . . .	259
H.4. Niveles de precisión alcanzados para los datos EmoExt Sujeto 2 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	260
H.5. Matriz de confusión para los datos EmoExt Sujeto 2 para diferentes variantes del cálculo de la de PSD . . . . .	261
H.6. Niveles de precisión alcanzados para los datos EmoExt Sujeto 3 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	262
H.7. Matriz de confusión para los datos EmoExt Sujeto 3 para diferentes variantes del cálculo de la de PSD . . . . .	263
H.8. Niveles de precisión alcanzados para los datos EmoExt Sujeto 4 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	264
H.9. Matriz de confusión para los datos EmoExt Sujeto 4 para diferentes variantes del cálculo de la de PSD . . . . .	265
H.10.Niveles de precisión alcanzados para los datos EmoExt Sujeto 5 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	266
H.11.Matriz de confusión para los datos EmoExt Sujeto 5 para diferentes variantes del cálculo de la de PSD . . . . .	267

H.12.Niveles de precisión alcanzados para los datos EmoExt Sujeto 6 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	268
H.13.Matriz de confusión para los datos EmoExt Sujeto 6 para diferentes variantes del cálculo de la de PSD . . . . .	269
H.14.Niveles de precisión alcanzados para los datos EmoExt Sujeto 7 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	270
H.15.Matriz de confusión para los datos EmoExt Sujeto 7 para diferentes variantes del cálculo de la de PSD . . . . .	271
H.16.Niveles de precisión alcanzados para los datos EmoExt Sujeto 8 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	272
H.17.Matriz de confusión para los datos EmoExt Sujeto 8 para diferentes variantes del cálculo de la de PSD . . . . .	273
H.18.Niveles de precisión alcanzados para los datos EmoExt Sujeto 9 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	274
H.19.Matriz de confusión para los datos EmoExt Sujeto 9 para diferentes variantes del cálculo de la de PSD . . . . .	275
H.20.Niveles de precisión alcanzados para los datos EmoExt Sujeto 10 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	276
H.21.Matriz de confusión para los datos EmoExt Sujeto 10 para diferentes variantes del cálculo de la de PSD . . . . .	277
H.22.Niveles de precisión alcanzados para los datos EmoExt Sujeto 11 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	278
H.23.Matriz de confusión para los datos EmoExt Sujeto 11 para diferentes variantes del cálculo de la de PSD . . . . .	279
H.24.Niveles de precisión alcanzados para los datos EmoExt Sujeto 12 para diferentes variantes del cálculo de la de PSD mostrados como % . . . . .	280
H.25.Matriz de confusión para los datos EmoExt Sujeto 12 para diferentes variantes del cálculo de la de PSD . . . . .	281
I.1. Datos capturados con Emotiv EPOC. Prueba 1 con realimentación. Comparativa basada en la tasa de acierto en % . . . . .	284
I.2. Matriz de confusión para los datos Emotiv EPOC para diferentes experimentos consecutivos con realimentación . . . . .	285
I.3. Datos capturados con Emotiv EPOC. Prueba 2 con realimentación. Comparativa basada en la tasa de acierto en % . . . . .	286
I.4. Matriz de confusión para los datos Emotiv EPOC para diferentes experimentos consecutivos con realimentación . . . . .	287
J.1. Matriz de confusión para los datos BCIComp Sujeto 1 para diferentes combinaciones de la metodología de selección de características . . . . .	290
J.2. Matriz de confusión para los datos BCIComp Sujeto 2 para diferentes combinaciones de la metodología de selección de características . . . . .	291
J.3. Matriz de confusión para los datos BCIComp Sujeto 3 para diferentes combinaciones de la metodología de selección de características . . . . .	292

K.1.	Matriz de confusión para los datos BCIEpoc Sujeto 1 para diferentes combinaciones de la metodología de selección de características . . . . .	294
K.2.	Matriz de confusión para los datos BCIEpoc Sujeto 2 para diferentes combinaciones de la metodología de selección de características . . . . .	295
K.3.	Matriz de confusión para los datos BCIEpoc Sujeto 3 para diferentes combinaciones de la metodología de selección de características . . . . .	296
L.1.	Matriz de confusión para los datos EmoEpoc Sujeto 1 para diferentes combinaciones de la metodología de selección de características . . . . .	298
L.2.	Matriz de confusión para los datos EmoEpoc Sujeto 2 para diferentes combinaciones de la metodología de selección de características . . . . .	299
L.3.	Matriz de confusión para los datos EmoEpoc Sujeto 3 para diferentes combinaciones de la metodología de selección de características . . . . .	300
M.1.	Matriz de confusión para los datos EasyBCI Sujeto 1 para diferentes combinaciones de la metodología de selección de características . . . . .	302
M.2.	Matriz de confusión para los datos EasyBCI Sujeto 2 para diferentes combinaciones de la metodología de selección de características . . . . .	303
M.3.	Matriz de confusión para los datos EasyBCI Sujeto 3 para diferentes combinaciones de la metodología de selección de características . . . . .	304
N.1.	Matriz de confusión para los datos EasyEpoc Sujeto 1 para diferentes combinaciones de la metodología de selección de características . . . . .	306
N.2.	Matriz de confusión para los datos EasyEpoc Sujeto 2 para diferentes combinaciones de la metodología de selección de características . . . . .	307
N.3.	Matriz de confusión para los datos EasyEpoc Sujeto 3 para diferentes combinaciones de la metodología de selección de características . . . . .	308
Ñ.1.	Matriz de confusión para los datos EmoExt Sujeto 1 para diferentes combinaciones de la metodología de selección de características . . . . .	310
Ñ.2.	Matriz de confusión para los datos EmoExt Sujeto 2 para diferentes combinaciones de la metodología de selección de características . . . . .	311
Ñ.3.	Matriz de confusión para los datos EmoExt Sujeto 3 para diferentes combinaciones de la metodología de selección de características . . . . .	312
Ñ.4.	Matriz de confusión para los datos EmoExt Sujeto 4 para diferentes combinaciones de la metodología de selección de características . . . . .	313
Ñ.5.	Matriz de confusión para los datos EmoExt Sujeto 5 para diferentes combinaciones de la metodología de selección de características . . . . .	314
Ñ.6.	Matriz de confusión para los datos EmoExt Sujeto 6 para diferentes combinaciones de la metodología de selección de características . . . . .	315
Ñ.7.	Matriz de confusión para los datos EmoExt Sujeto 7 para diferentes combinaciones de la metodología de selección de características . . . . .	316
Ñ.8.	Matriz de confusión para los datos EmoExt Sujeto 8 para diferentes combinaciones de la metodología de selección de características . . . . .	317

Ñ.9. Matriz de confusión para los datos EmoExt Sujeto 9 para diferentes combinaciones de la metodología de selección de características . . . . .	318
Ñ.10. Matriz de confusión para los datos EmoExt Sujeto 10 para diferentes combinaciones de la metodología de selección de características . . . . .	319
Ñ.11. Matriz de confusión para los datos EmoExt Sujeto 11 para diferentes combinaciones de la metodología de selección de características . . . . .	320
Ñ.12. Matriz de confusión para los datos EmoExt Sujeto 12 para diferentes combinaciones de la metodología de selección de características . . . . .	321
O.1. Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Método Estadístico + Selección por Orden . . . . .	323
O.2. Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Método Estadístico + Selección GMDH . . . . .	324
O.3. Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Criterio Difuso + Selección por Orden . . . . .	324
O.4. Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Criterio Difuso + Selección GMDH . . . . .	325





## Apéndice A

# Cuestionario posterior a la toma de datos

Se recogen en este apéndice los datos obtenidos a partir del cuestionario rellenado por los colaboradores en la base de datos extendida EmoExt.

### A.1. Preguntas incluidas

El cuestionario se desarrolló como una herramienta que permitiese mejorar experimentos posteriores utilizando como dispositivo de captura de datos EEG. Tres bloques se diferenciaron en el mismo:

1. Información personal. Esta parte del cuestionario estaba destinada a capturar información relacionada con la demografía de la población.
2. Comodidad EPOC. Una de las áreas que se quiso clarificar era la percepción de los usuarios acerca del sistema EEG utilizado. Existen multitud de estudios que hablan de la democratización de los sistemas EEG y de sus posibles aplicaciones en la vida diaria, estableciendo la facilidad de uso como un requisito fundamental. Sin embargo, no se ha encontrado en la literatura ningún estudio que recoja la percepción real de los usuarios tras llevar un sistema este tipo. Sólo tres preguntas se incluyeron en este bloque .
3. Dificultad de los experimentos. Una vez evaluado del sistema de captura de datos, se consideró relevante obtener información acerca de la dificultad percibida realizando el experimento. Cinco preguntas compusieron este bloque.
4. Mejoras futuras. De forma voluntaria, los sujetos pudieron sugerir mejoras.

Evidentemente, el marco de esta tesis doctoral no incluye rediseñar el dispositivo EEG de captura de datos o el experimento que, con el objetivo de ofrecer unos resultados comparables, se ciñió al establecido en el BCI Competition V dataset V.

## **Formulario Experimento Captura datos EEG**

### **Bloque 1. Información Demográfica**

Nombre y Apellidos:

Sexo:

Año de Nacimiento:

Zurdo o diestro:

¿Tiene algún conocimiento previo del mundo de las EEG?: Sí ☐ No ☐

### **Bloque 2. Comodidad**

Q1. ¿Le ha parecido cómodo el procedimiento de colocación del dispositivo?

1. Muy incómodo ☐ 2. Incómodo ☐ 3. Normal ☐ 4. Cómodo ☐ 5. Muy cómodo ☐

Q2. ¿Le ha resultado molesto realizar los experimentos con el casco puesto?

1. Muy molesto ☐ 2. Molesto ☐ 3. Normal ☐ 4. Cómodo ☐ 5. Muy cómodo ☐

Q3. ¿Se ha sentido a gusto y relajado en la posición en la que ha realizado el experimento?

1. Muy incómodo ☐ 2. Incómodo ☐ 3. Normal ☐ 4. Relajado ☐ 5. Muy relajado ☐

### **Bloque 3. Dificultad de los experimentos**

Q1. ¿Le ha parecido difícil realizar los experimentos?

1. Muy fácil ☐ 2. Fácil ☐ 3. Normal ☐ 4. Difícil ☐ 5. Muy Difícil ☐

Q2. ¿Le ha generado cansancio la realización del experimento?

1. Ninguno ☐ 2. Muy Poco ☐ 3. Un Poco ☐ 4. Bastante ☐ 5. Excesivo ☐

Q3. ¿El tiempo de descanso entre cada sesión ha sido el correcto?

1. Demasiado corto ☐ 2. Corto ☐ 3. Adecuado ☐ 4. Largo ☐ 5. Demasiado Largo ☐

Q4. ¿Considera que la realización del experimento ha sido satisfactoria en líneas generales?

1. Para nada ☐ 2. Un Poco ☐ 3. Normal ☐ 4. Bastante ☐ 5. Completamente ☐

Q5. ¿En cuál de las tres tareas le ha resultado más difícil concentrarse?

Mano derecha ☐ Mano Izquierda ☐ Palabra ☐

Para finalizar, nos gustaría saber globalmente qué le ha parecido la realización del experimento y qué aspectos podríamos mejorar de cara al futuro:

.....  
.....

## Apéndice B

# Resultados S-dFasArt - Base de Datos BCIComp

Las siguientes tablas muestran los resultados obtenidos para cada Sujeto para diferentes valores del parámetro velocidad de reset  $A_r$ .

Tabla B.1: Datos preprocesados BCI Competition III dataset V. Comparativa acierto entre usuarios. Tasa de acierto en %

Usuario	Valor $A_r$		
	-	<b>0.05</b>	-
Sujeto 1	-	87.67	-
Sujeto 2	-	82.03	-
Sujeto 3	-	58.72	-

## BCIComp Sujeto 1




Figura B.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIComp. Sujeto 1. Diferentes  $A_r$ .

Tabla B.2: Niveles de precisión alcanzados para los datos BCIComp Sujeto 1 para diferentes valores de  $A_r$  mostrados como %

BCIComp Sujeto 1					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.05	87.67	92.47	78.91	92.31	90.56

Tabla B.3: Matriz de confusión para los datos BCIComp Sujeto 1 para diferentes valores de  $A_r$

BCIComp Sujeto 1				
$A_r = 0.05$				
<b>87.67</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	
Real Izquierda	120	5	5	
Real Derecha	16	101	11	
Real Palabra	10	7	163	

## BCIComp Sujeto 2




Figura B.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIComp. Sujeto 2. Diferentes  $A_r$ .

Tabla B.4: Niveles de precisión alcanzados para los datos BCIComp Sujeto 2 para diferentes valores de  $A_r$  mostrados como %

BCIComp Sujeto 2					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.05	82.26	88.02	81.25	77.78	85.71

Tabla B.5: Matriz de confusión para los datos BCIComp Sujeto 2 para diferentes valores de  $A_r$

BCIComp Sujeto 2				
$A_r = 0.05$				
<b>87.67</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	
Real Izquierda	84	21	3	
Real Derecha	4	117	23	
Real Palabra	16	10	156	

### BCIComp Sujeto 3




Figura B.3: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIComp. Sujeto 3. Diferentes  $A_r$ .

Tabla B.6: Niveles de precisión alcanzados para los datos BCIComp Sujeto 3 para diferentes valores de  $A_r$  mostrados como %

BCIComp Sujeto 3					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.05	58.72	75.23	73.97	24.00	80.00

Tabla B.7: Matriz de confusión para los datos BCIComp Sujeto 3 para diferentes valores de  $A_r$

BCIComp Sujeto 3				
$A_r = 0.05$				
<b>87.67</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	
Real Izquierda	36	59	55	
Real Derecha	13	108	25	
Real Palabra	14	14	112	

## Apéndice C

# Resultados S-dFasArt - Base de Datos BCIEpoc

Las siguientes tablas muestran los resultados obtenidos para cada Sujeto para diferentes valores del parámetro velocidad de reset  $A_r$ .

Tabla C.1: Datos BCI Competition - Posiciones Emotiv. Comparativa acierto entre usuarios. Tasa de acierto en %

Usuario	Valor $A_r$		
	0.001	0.002	0.003
Sujeto 1	56.60	<b>63.40</b>	61.06
Sujeto 2	50.84	<b>59.07</b>	57.38
Sujeto 3	36.34	<b>42.23</b>	40.55

## BCIEpoc Sujeto 1

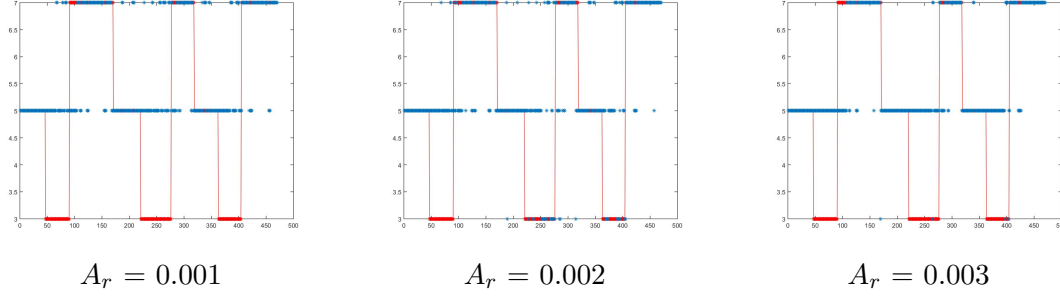


Figura C.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIEpoc. Sujeto 1. Diferentes  $A_r$

Tabla C.2: Niveles de precisión alcanzados para los datos BCIEpoc Sujeto 1 para diferentes valores de  $A_r$  mostrados como %

BCIEpoc Sujeto 1					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	56.60	80.43	91.43	0.00	73.40
0.002	63.40	83.19	93.57	19.72	73.94
0.003	61.06	89.15	98.57	2.11	77.66

Tabla C.3: Matriz de confusión para los datos BCIEpoc Sujeto 1 para diferentes valores de  $A_r$

BCIEpoc Sujeto 1			
$A_r = 0.001$			
56.60	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	0	112	30
Real Derecha	0	128	12
Real Palabra	0	50	138
$A_r = 0.002$			
63.40	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	28	92	22
Real Derecha	1	131	8
Real Palabra	4	45	139
$A_r = 0.003$			
63.40	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	3	132	7
Real Derecha	0	138	2
Real Palabra	1	41	146



## BCIEpoc Sujeto 2

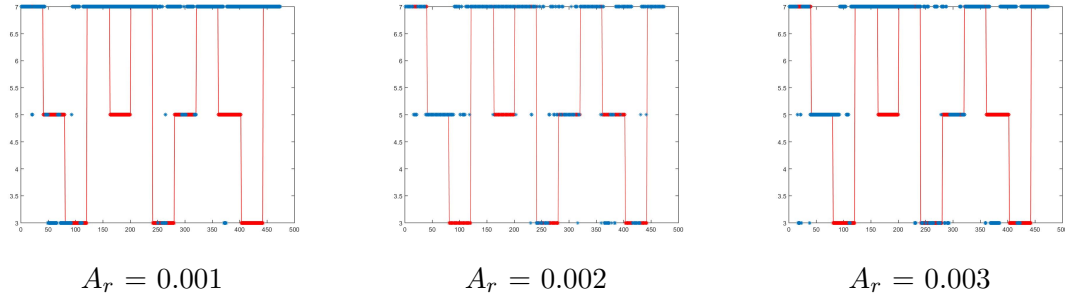


Figura C.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIEpoc. Sujeto 2. Diferentes  $A_r$

Tabla C.4: Niveles de precisión alcanzados para los datos BCIEpoc Sujeto 2 para diferentes valores de  $A_r$  mostrados como %

BCIEpoc Sujeto 2					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	50.84	57.81	13.75	22.50	98.97
0.002	59.07	68.35	46.25	25.83	90.21
0.003	57.38	66.67	39.37	26.67	91.24

Tabla C.5: Matriz de confusión para los datos BCIEpoc Sujeto 2 para diferentes valores de  $A_r$

BCIEpoc Sujeto 2			
$A_r = 0.001$			
<b>50.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	27	2	91
Real Derecha	31	22	107
Real Palabra	0	2	192
$A_r = 0.002$			
<b>59.07</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	31	29	60
Real Derecha	15	74	71
Real Palabra	3	16	175
$A_r = 0.003$			
<b>57.38</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	32	18	70
Real Derecha	26	63	71
Real Palabra	11	6	177

### BCIEpoc Sujeto 3

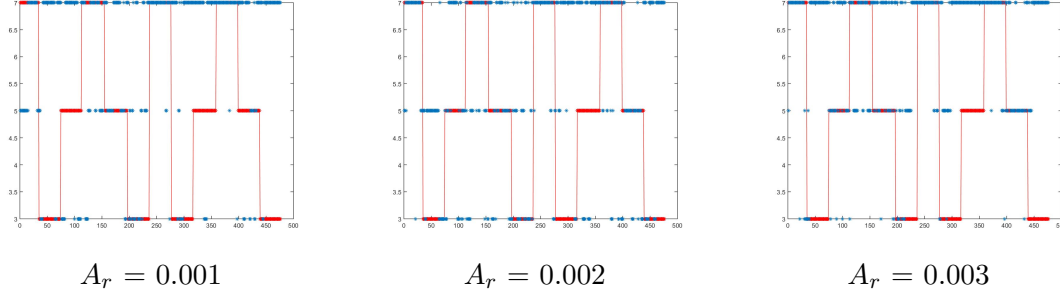


Figura C.3: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIEpoc. Sujeto 3. Diferentes  $A_r$

Tabla C.6: Niveles de precisión alcanzados para los datos BCIEpoc Sujeto 3 para diferentes valores de  $A_r$  mostrados como %

BCIEpoc Sujeto 3					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	36.34	46.01	16.05	19.62	74.36
0.002	42.23	59.45	32.72	26.58	67.95
0.003	40.55	49.16	36.42	8.86	76.92

Tabla C.7: Matriz de confusión para los datos BCIEpoc Sujeto 3 para diferentes valores de  $A_r$

BCIEpoc Sujeto 3			
$A_r = 0.001$			
<b>36.34</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	31	17	110
Real Derecha	29	26	107
Real Palabra	7	33	116
$A_r = 0.002$			
<b>42.23</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	42	45	71
Real Derecha	37	53	72
Real Palabra	20	30	106
$A_r = 0.003$			
<b>40.55</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	14	34	110
Real Derecha	7	59	96
Real Palabra	7	29	120

## Apéndice D

# Resultados S-dFasArt - Base de Datos EmoEpoc

Las siguientes tablas muestran los resultados obtenidos para cada Sujeto para diferentes valores del parámetro velocidad de reset  $A_r$ . El resultado incluido en esta tesis doctoral como mejor resultado para el Sujeto 3 es el conseguido con  $A_r=0.002$  dado que cuando se escribió el artículo [160] aún no se había obtenido el resultado para  $A_r=0.003$ .

Tabla D.1: Datos capturados con Emotiv EPOC. Comparativa acierto entre usuarios. Tasa de acierto en %.

Usuario	Valor $A_r$		
	0.001	0.002	0.003
Sujeto 1	<b>69.04</b>	62.76	61.51
Sujeto 2	48.81	<b>63.50</b>	45.79
Sujeto 3	54.00	55.29*	<b>57.02</b>

## EmoEpoc Sujeto 1

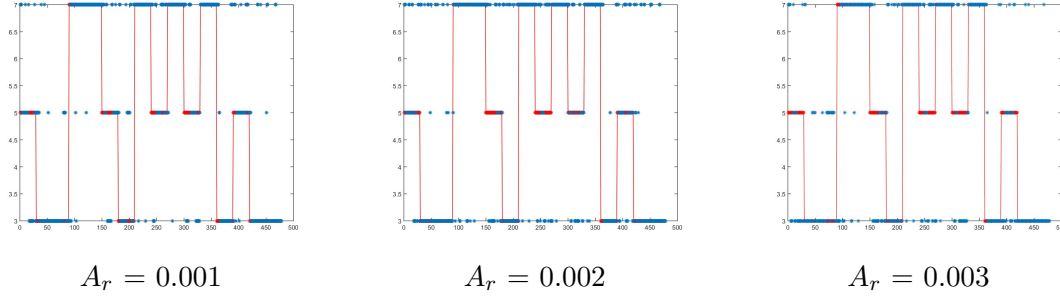


Figura D.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoEpoc. Sujeto 1. Diferentes  $A_r$

Tabla D.2: Niveles de precisión alcanzados para los datos EmoEpoc Sujeto 1 para diferentes valores de  $A_r$  mostrados como %

EmoEpoc Sujeto 1					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	69.04	82.22	41.61	72.63	92.00
0.002	62.76	75.32	27.52	70.39	88.67
0.003	61.51	83.26	18.12	76.54	86.87

Tabla D.3: Matriz de confusión para los datos EmoEpoc Sujeto 1 para diferentes valores de  $A_r$

EmoEpoc Sujeto 1			
$A_r = 0.001$			
<b>69.04</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	130	25	24
Real Derecha	38	62	49
Real Palabra	8	4	138
$A_r = 0.002$			
<b>62.76</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	126	8	45
Real Derecha	52	41	56
Real Palabra	16	1	133
$A_r = 0.003$			
<b>61.51</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	137	20	22
Real Derecha	84	27	38
Real Palabra	17	3	130

## EmoEpoc Sujeto 2

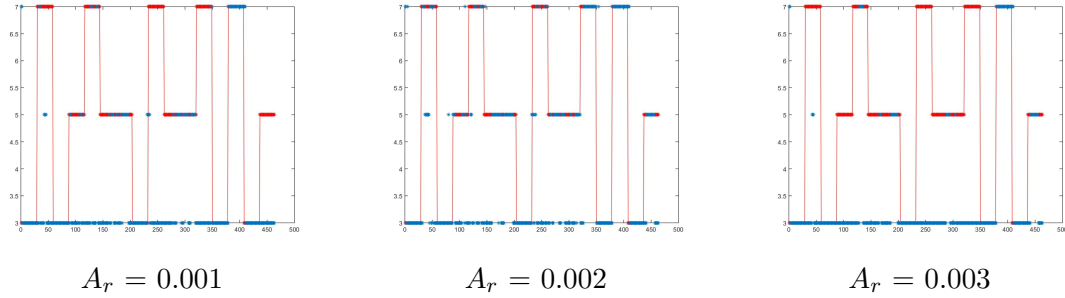


Figura D.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoEpoc. Sujeto 2. Diferentes  $A_r$

Tabla D.4: Niveles de precisión alcanzados para los datos EmoEpoc Sujeto 2 para diferentes valores de  $A_r$  mostrados como %

EmoEpoc Sujeto 2					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	48.81	75.81	29.31	95.17	25.69
0.002	63.50	82.51	49.43	93.79	50.00
0.003	45.79	75.38	21.26	96.55	24.31

Tabla D.5: Matriz de confusión para los datos EmoEpoc Sujeto 2 para diferentes valores de  $A_r$

EmoEpoc Sujeto 2			
$A_r = 0.001$			
<b>48.81</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	138	2	5
Real Derecha	123	51	0
Real Palabra	100	7	37
$A_r = 0.002$			
<b>63.50</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	136	2	7
Real Derecha	86	86	2
Real Palabra	56	16	72
$A_r = 0.003$			
<b>45.79</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	140	0	5
Real Derecha	137	37	0
Real Palabra	106	3	35

### EmoEpoc Sujeto 3

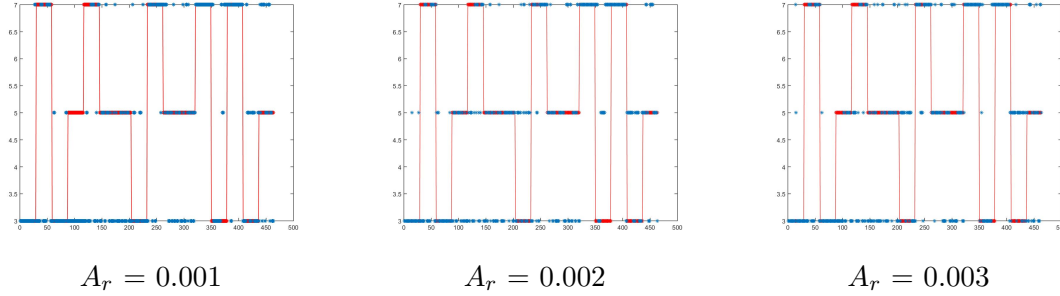


Figura D.3: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoEpoc. Sujeto 3. Diferentes  $A_r$

Tabla D.6: Niveles de precisión alcanzados para los datos EmoEpoc Sujeto 3 para diferentes valores de  $A_r$  mostrados como %

EmoEpoc Sujeto 3					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	54.00	80.56	28.90	70.34	67.59
0.002	55.29	80.35	47.40	53.10	66.90
0.003	57.02	81.86	43.35	62.76	67.59

Tabla D.7: Matriz de confusión para los datos EmoEpoc Sujeto 3 para diferentes valores de  $A_r$

EmoEpoc Sujeto 3			
$A_r = 0.001$			
<b>54.00</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	102	25	18
Real Derecha	98	50	25
Real Palabra	43	4	98
$A_r = 0.002$			
<b>55.29</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	77	47	21
Real Derecha	69	82	22
Real Palabra	37	11	97
$A_r = 0.003$			
<b>57.02</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	91	39	15
Real Derecha	76	75	22
Real Palabra	32	15	98

## Apéndice E

# Resultados S-dFasArt - Base de Datos EasyBCI

Las siguientes tablas muestran los resultados obtenidos para cada Sujeto para diferentes valores del parámetro velocidad de reset  $A_r$ .

Tabla E.1: Datos capturados con Emotiv EasyCap - Posiciones BCI Competition. Comparativa acierto entre usuarios. Tasa de acierto en %

Usuario	Valor $A_r$		
	0.001	0.002	0.003
Sujeto 1	<b>75.52</b>	71.13	72.38
Sujeto 2	64.64	<b>65.48</b>	62.97
Sujeto 3	<b>58.58</b>	54.81	53.77

## EasyBCI Sujeto 1

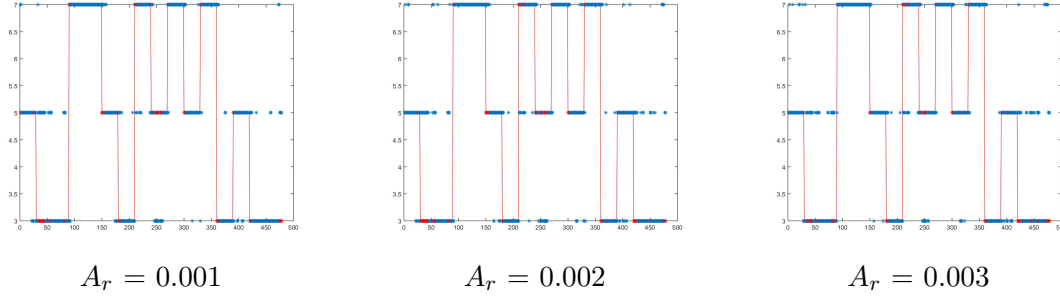


Figura E.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra - *P*. Datos EasyBCI. Sujeto 1. Diferentes  $A_r$

Tabla E.2: Niveles de precisión alcanzados para los datos EasyBCI Sujeto 1 para diferentes valores de  $A_r$  mostrados como %

EasyBCI Sujeto 1					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	75.52	91.42	67.11	71.51	88.67
0.002	71.13	88.70	60.40	65.82	88.00
0.003	72.38	90.38	67.79	62.57	88.67

Tabla E.3: Matriz de confusión para los datos EasyBCI Sujeto 1 para diferentes valores de  $A_r$

EasyBCI Sujeto 1			
$A_r = 0.001$			
<b>75.52</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	128	44	7
Real Derecha	32	100	17
Real Palabra	5	12	133
$A_r = 0.002$			
<b>71.13</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	118	48	13
Real Derecha	36	90	23
Real Palabra	6	2	132
$A_r = 0.003$			
<b>72.38</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	112	56	11
Real Derecha	30	101	18
Real Palabra	1	16	133



## EasyBCI Sujeto 2

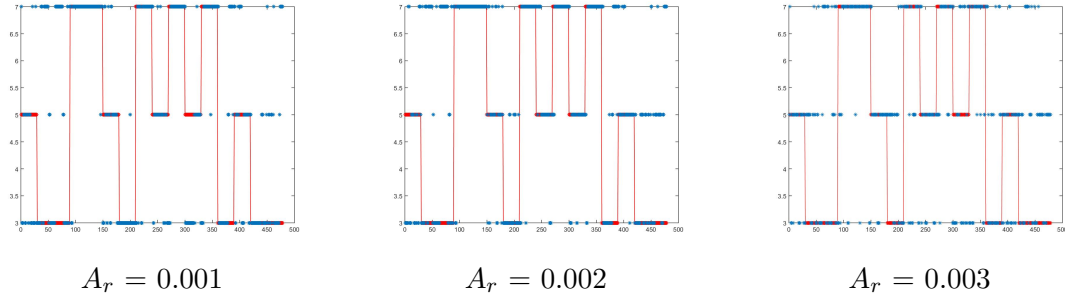


Figura E.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyBCI. Sujeto 2. Diferentes  $A_r$

Tabla E.4: Niveles de precisión alcanzados para los datos EasyBCI Sujeto 2 para diferentes valores de  $A_r$  mostrados como %

EasyBCI Sujeto 2					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	64.64	81.80	43.62	63.13	87.33
0.002	65.48	80.13	60.40	49.16	90.00
0.003	62.97	81.17	38.26	63.69	86.67

Tabla E.5: Matriz de confusión para los datos EasyBCI Sujeto 2 para diferentes valores de  $A_r$

EasyBCI Sujeto 2			
$A_r = 0.001$			
<b>64.64</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	113	20	46
Real Derecha	62	65	22
Real Palabra	17	2	131
$A_r = 0.002$			
<b>65.48</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	88	40	51
Real Derecha	30	90	29
Real Palabra	9	6	135
$A_r = 0.003$			
<b>62.97</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	114	20	45
Real Derecha	67	57	25
Real Palabra	16	4	130

### EasyBCI Sujeto 3

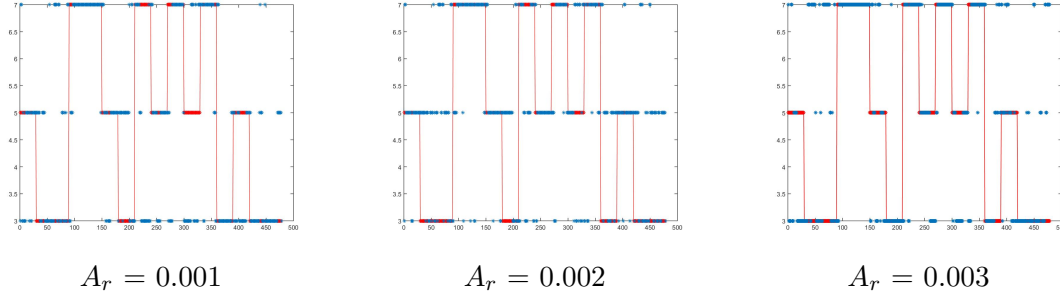


Figura E.3: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyBCI. Sujeto 3. Diferentes  $A_r$

Tabla E.6: Niveles de precisión alcanzados para los datos EasyBCI Sujeto 3 para diferentes valores de  $A_r$  mostrados como %

EasyBCI Sujeto 3					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	58.58	82.01	45.64	59.78	70.00
0.002	54.81	79.29	73.15	31.28	64.67
0.003	53.77	78.08	58.39	39.11	66.67

Tabla E.7: Matriz de confusión para los datos EasyBCI Sujeto 3 para diferentes valores de  $A_r$

EasyBCI Sujeto 3			
$A_r = 0.001$			
<b>58.58</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	107	51	21
Real Derecha	61	68	20
Real Palabra	30	15	105
$A_r = 0.002$			
<b>54.81</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	56	98	25
Real Derecha	19	109	21
Real Palabra	22	31	97
$A_r = 0.003$			
<b>53.77</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	70	73	36
Real Derecha	43	87	19
Real Palabra	26	24	100

## Apéndice F

# Resultados S-dFasArt - Base de Datos EasyEpoc

Las siguientes tablas muestran los resultados obtenidos para cada Sujeto para diferentes valores del parámetro velocidad de reset  $A_r$ .

Tabla F.1: Datos capturados con Emotiv EasyCap - Posiciones Emotiv EPOC. Comparativa acierto entre usuarios. Tasa de acierto en %

Usuario	Valor $A_r$		
	0.001	0.002	0.003
Sujeto 1	53.77	53.77	<b>56.07</b>
Sujeto 2	<b>54.81</b>	52.72	52.51
Sujeto 3	40.17	41.84	<b>47.07</b>

## EasyEpoc Sujeto 1

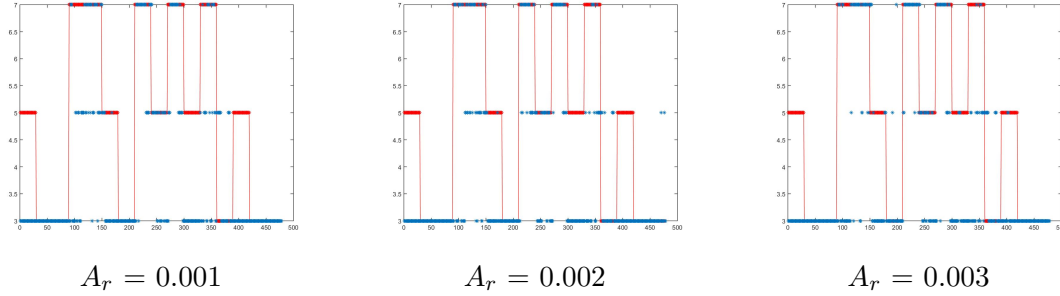


Figura F.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EasyEpoc. Sujeto 1. Diferenes  $A_r$

Tabla F.2: Niveles de precisión alcanzados para los datos EasyEpoc Sujeto 1 para diferentes valores de  $A_r$  mostrados como %

EasyEpoc Sujeto 1					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	53.77	81.80	15.44	93.85	44.00
0.002	53.77	82.43	13.42	94.97	44.67
0.003	56.07	83.47	15.44	93.30	52.00

Tabla F.3: Matriz de confusión para los datos EasyEpoc Sujeto 1 para diferentes valores de  $A_r$

EasyEpoc Sujeto 1			
$A_r = 0.001$			
<b>53.77</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	168	11	0
Real Derecha	123	23	3
Real Palabra	36	48	66
$A_r = 0.002$			
<b>53.77</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	170	9	0
Real Derecha	128	20	1
Real Palabra	38	45	67
$A_r = 0.003$			
<b>56.07</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	167	11	1
Real Derecha	120	23	6
Real Palabra	47	25	78

## EasyEpoc Sujeto 2

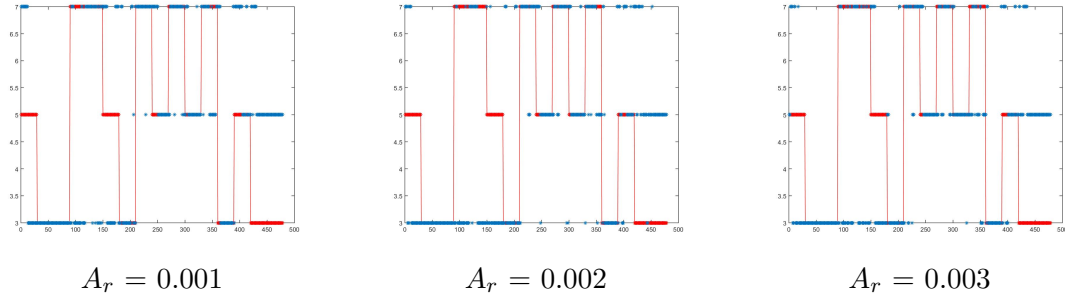


Figura F.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EasyEpoc. Sujeto 2. Diferenes  $A_r$ .

Tabla F.4: Niveles de precisión alcanzados para los datos EasyEpoc Sujeto 2 para diferentes valores de  $A_r$  mostrados como %

EasyEpoc Sujeto 2					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	54.81	72.59	38.26	58.66	66.67
0.002	52.72	74.06	40.27	61.45	54.67
0.003	52.51	74.06	46.98	61.45	47.33

Tabla F.5: Matriz de confusión para los datos EasyEpoc Sujeto 2 para diferentes valores de  $A_r$

EasyEpoc Sujeto 2			
$A_r = 0.001$			
<b>54.81</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	105	51	23
Real Derecha	34	57	58
Real Palabra	30	20	100
$A_r = 0.002$			
<b>52.72</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	110	47	22
Real Derecha	55	60	34
Real Palabra	48	20	82
$A_r = 0.003$			
<b>52.51</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	110	54	15
Real Derecha	49	70	30
Real Palabra	47	32	71

## EasyEpoc Sujeto 3

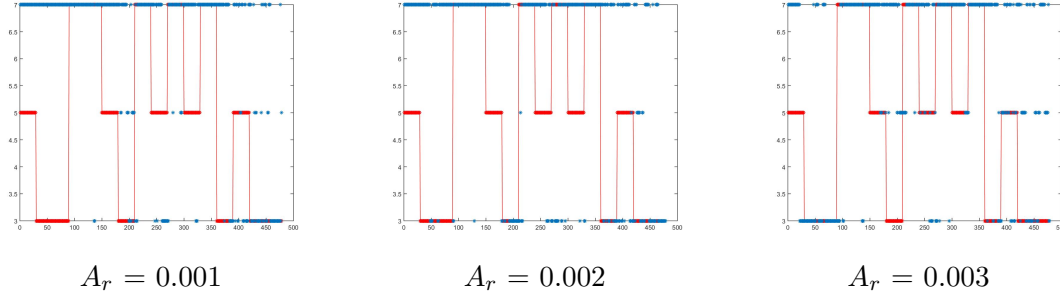


Figura F.3: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyEpoc. Sujeto 3. Diferenes  $A_r$

Tabla F.6: Niveles de precisión alcanzados para los datos EasyEpoc Sujeto 3 para diferentes valores de  $A_r$  mostrados como %

EasyEpoc Sujeto 3					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	40.17	49.37	1.34	29.05	92.00
0.002	41.84	47.77	0.67	41.34	83.33
0.003	47.07	57.53	18.12	41.34	82.67

Tabla F.7: Matriz de confusión para los datos EasyEpoc Sujeto 3 para diferentes valores de  $A_r$

EasyEpoc Sujeto 3			
$A_r = 0.001$			
<b>40.17</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	52	17	110
Real Derecha	27	2	120
Real Palabra	8	4	138
$A_r = 0.002$			
<b>41.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	74	8	97
Real Derecha	20	1	128
Real Palabra	24	1	125
$A_r = 0.003$			
<b>47.07</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	74	30	75
Real Derecha	20	27	102
Real Palabra	17	9	124

## Apéndice G

# Resultados S-dFasArt - Base de Datos EmoExt

Las siguientes tablas muestran los resultados obtenidos para cada Sujeto para diferentes valores del parámetro velocidad de reset  $A_r$ .

Tabla G.1: Datos capturados con Emotiv EPOC. Base de datos Extendida. Comparativa acierto entre usuarios. Tasa de acierto en %

Usuario	Valor $A_r$		
	0.001	0.002	0.003
Sujeto 1	65.48	<b>67.57</b>	61.51
Sujeto 2	<b>62.97</b>	62.76	61.51
Sujeto 3	61.92	<b>62.55</b>	58.16
Sujeto 4	55.65	<b>61.09</b>	55.86
Sujeto 5	<b>60.67</b>	49.79	57.32
Sujeto 6	<b>57.95</b>	56.49	53.77
Sujeto 7	52.72	<b>55.02</b>	42.05
Sujeto 8	43.31	<b>53.56</b>	50.21
Sujeto 9	50.42	50.84	<b>52.72</b>
Sujeto 10	51.05	45.19	<b>51.67</b>
Sujeto 11	45.19	<b>50.00</b>	47.49
Sujeto 12	36.40	<b>48.12</b>	40.79

## EmoExt Sujeto 1

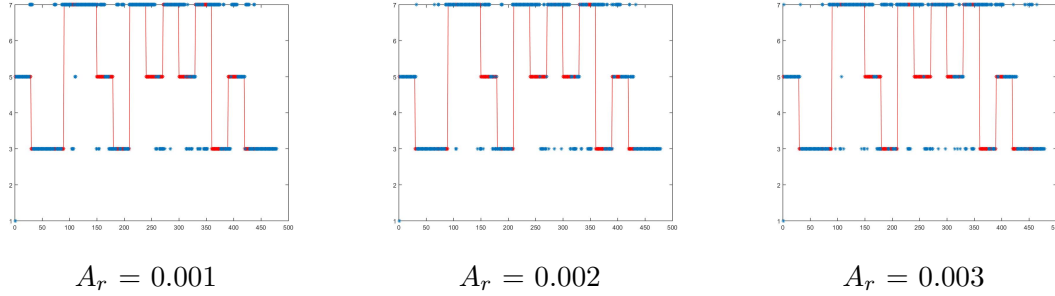


Figura G.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 1. Diferentes  $A_r$

Tabla G.2: Niveles de precisión alcanzados para los datos EmoExt Sujeto 1 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 1					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	65.48	72.80	39.33	72.07	83.89
0.002	67.57	75.73	40.67	73.74	87.25
0.003	61.51	67.78	44.00	59.78	81.21

Tabla G.3: Matriz de confusión para los datos EmoExt Sujeto 1 para diferentes valores de  $A_r$

EmoExt Sujeto 1			
$A_r = 0.001$			
<b>65.48</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	129	1	49
Real Derecha	34	59	56
Real Palabra	21	3	125
$A_r = 0.002$			
<b>67.57</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	132	10	37
Real Derecha	29	61	59
Real Palabra	18	1	130
$A_r = 0.003$			
<b>61.51</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	107	9	63
Real Derecha	21	66	62
Real Palabra	26	2	121



## EmoExt Sujeto 2

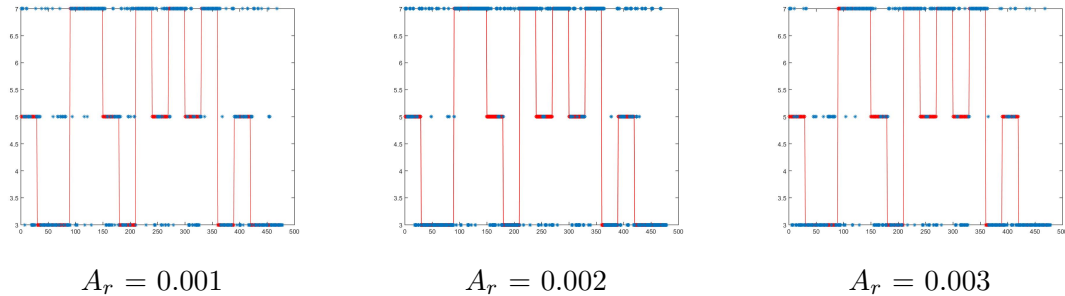


Figura G.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 2. Diferentes  $A_r$

Tabla G.4: Niveles de precisión alcanzados para los datos EmoExt Sujeto 2 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 2					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	62.97	81.17	38.93	62.01	88.00
0.002	62.76	75.31	27.52	70.39	88.67
0.003	61.51	83.26	18.12	76.54	86.87

Tabla G.5: Matriz de confusión para los datos EmoExt Sujeto 2 para diferentes valores de  $A_r$

EmoExt Sujeto 2			
$A_r = 0.001$			
<b>62.97</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	111	33	35
Real Derecha	54	58	37
Real Palabra	10	8	132
$A_r = 0.002$			
<b>62.76</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	126	8	45
Real Derecha	52	41	56
Real Palabra	16	1	133
$A_r = 0.003$			
<b>61.51</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	137	20	22
Real Derecha	84	27	38
Real Palabra	17	3	130

## EmoExt Sujeto 3

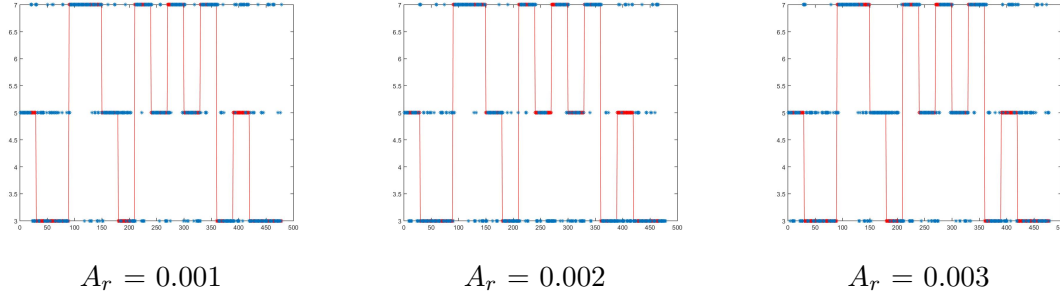


Figura G.3: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 3. Diferentes  $A_r$

Tabla G.6: Niveles de precisión alcanzados para los datos EmoExt Sujeto 3 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 3					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	61.92	80.54	55.70	56.42	74.67
0.002	62.55	89.94	44.30	69.83	72.00
0.003	58.16	83.05	61.74	45.25	70.00

Tabla G.7: Matriz de confusión para los datos EmoExt Sujeto 3 para diferentes valores de  $A_r$

EmoExt Sujeto 3			
$A_r = 0.001$			
<b>61.92</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	101	56	22
Real Derecha	33	83	33
Real Palabra	17	21	112
$A_r = 0.002$			
<b>62.55</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	125	38	16
Real Derecha	69	66	14
Real Palabra	33	9	108
$A_r = 0.003$			
<b>58.16</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	81	80	18
Real Derecha	39	92	18
Real Palabra	25	20	105

## EmoExt Sujeto 4

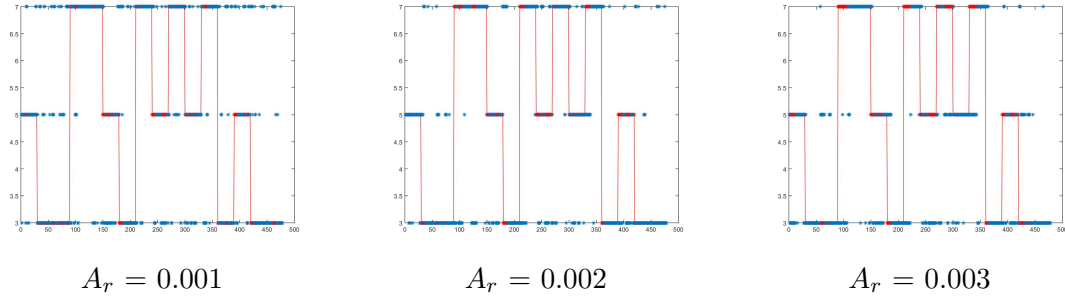


Figura G.4: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 4. Diferentes  $A_r$

Tabla G.8: Niveles de precisión alcanzados para los datos EmoExt Sujeto 4 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 4					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	55.65	71.97	42.95	55.87	68.00
0.002	61.09	77.62	41.61	77.09	61.33
0.003	55.86	79.08	41.61	75.42	46.67

Tabla G.9: Matriz de confusión para los datos EmoExt Sujeto 4 para diferentes valores de  $A_r$

EmoExt Sujeto 4			
$A_r = 0.001$			
<b>55.65</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	100	25	54
Real Derecha	53	64	32
Real Palabra	34	14	102
$A_r = 0.002$			
<b>61.09</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	138	15	26
Real Derecha	64	62	23
Real Palabra	44	14	92
$A_r = 0.003$			
<b>55.86</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	135	34	10
Real Derecha	77	62	10
Real Palabra	44	36	70

## EmoExt Sujeto 5

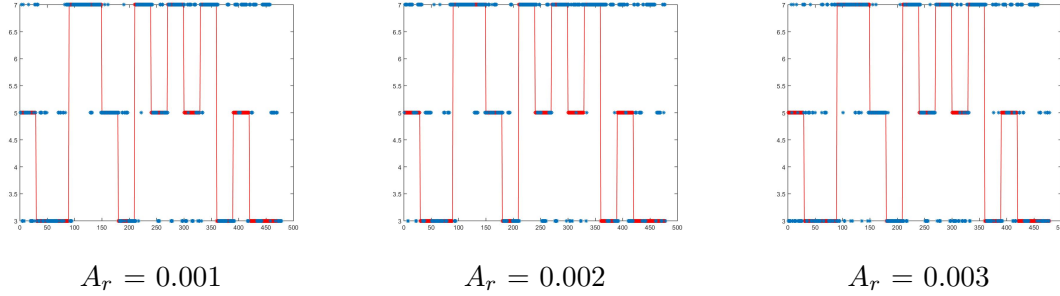


Figura G.5: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 5. Diferentes  $A_r$

Tabla G.10: Niveles de precisión alcanzados para los datos EmoExt Sujeto 5 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 5					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	60.67	75.73	47.65	53.63	82.00
0.002	49.79	65.49	26.85	40.22	84.00
0.003	57.32	74.27	43.62	54.75	74.00

Tabla G.11: Matriz de confusión para los datos EmoExt Sujeto 5 para diferentes valores de  $A_r$

EmoExt Sujeto 5			
$A_r = 0.001$			
<b>60.67</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	96	40	43
Real Derecha	32	71	46
Real Palabra	17	10	123
$A_r = 0.002$			
<b>49.79</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	72	44	63
Real Derecha	32	40	77
Real Palabra	13	11	126
$A_r = 0.003$			
<b>57.32</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	98	29	52
Real Derecha	52	65	32
Real Palabra	27	12	111

## EmoExt Sujeto 6

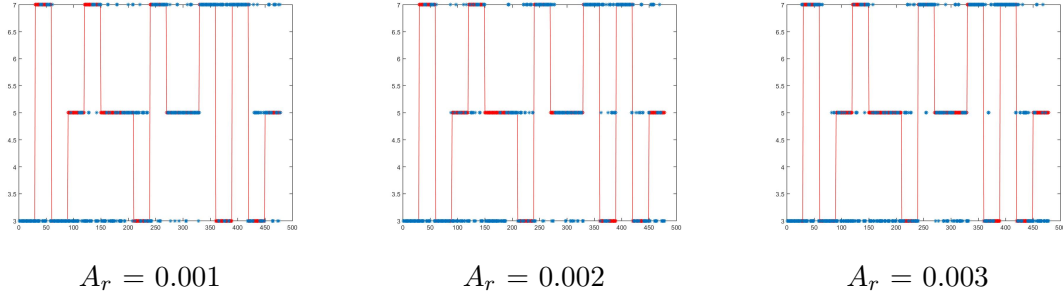


Figura G.6: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 6. Diferentes  $A_r$

Tabla G.12: Niveles de precisión alcanzados para los datos EmoExt Sujeto 6 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 6					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	57.95	77.82	49.72	59.73	66.00
0.002	56.49	79.71	41.90	61.74	68.74
0.003	53.77	81.38	31.84	63.09	70.67

Tabla G.13: Matriz de confusión para los datos EmoExt Sujeto 6 para diferentes valores de  $A_r$

EmoExt Sujeto 6			
$A_r = 0.001$			
<b>57.95</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	89	31	29
Real Derecha	64	89	26
Real Palabra	47	4	99
$A_r = 0.002$			
<b>56.49</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	92	27	30
Real Derecha	84	75	20
Real Palabra	37	10	103
$A_r = 0.003$			
<b>53.77</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	94	24	31
Real Derecha	108	57	14
Real Palabra	36	8	106

## EmoExt Sujeto 7

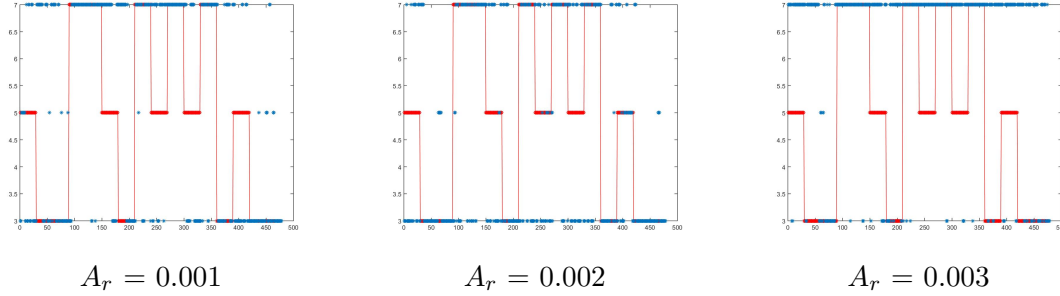


Figura G.7: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 7. Diferentes  $A_r$

Tabla G.14: Niveles de precisión alcanzados para los datos EmoExt Sujeto 7 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 7					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	52.72	69.25	4.70	64.08	86.00
0.002	55.02	73.01	13.42	82.12	64.00
0.003	42.05	46.23	0.00	33.52	94.00

Tabla G.15: Matriz de confusión para los datos EmoExt Sujeto 7 para diferentes valores de  $A_r$

EmoExt Sujeto 7			
$A_r = 0.001$			
<b>52.72</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	116	9	54
Real Derecha	70	7	72
Real Palabra	20	1	129
$A_r = 0.002$			
<b>55.02</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	147	10	22
Real Derecha	76	20	53
Real Palabra	54	4	96
$A_r = 0.003$			
<b>42.05</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	60	4	115
Real Derecha	16	0	133
Real Palabra	9	0	141

## EmoExt Sujeto 8

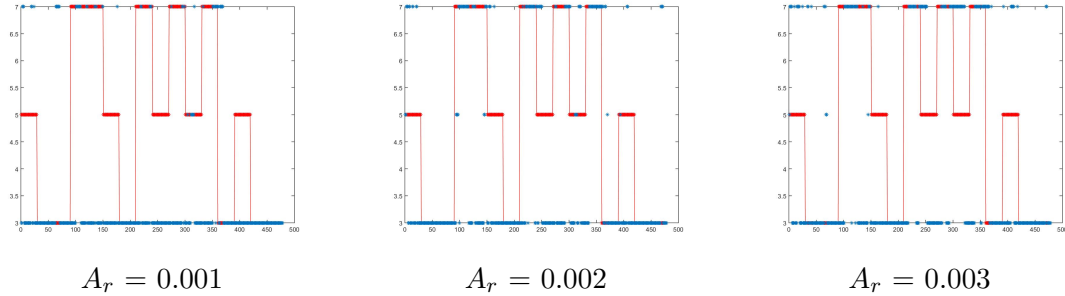


Figura G.8: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 8. Diferentes  $A_r$

Tabla G.16: Niveles de precisión alcanzados para los datos EmoExt Sujeto 8 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 8					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	43.31	70.92	4.76	91.71	22.67
0.002	53.56	76.99	4.76	94.48	52.00
0.003	50.21	70.08	0.68	90.06	50.67

Tabla G.17: Matriz de confusión para los datos EmoExt Sujeto 8 para diferentes valores de  $A_r$

EmoExt Sujeto 8			
$A_r = 0.001$			
<b>43.31</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	166	0	15
Real Derecha	132	7	8
Real Palabra	116	0	134
$A_r = 0.002$			
<b>53.56</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	171	1	9
Real Derecha	111	7	29
Real Palabra	66	6	78
$A_r = 0.003$			
<b>50.21</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	163	2	16
Real Derecha	92	1	53
Real Palabra	73	1	76

## EmoExt Sujeto 9

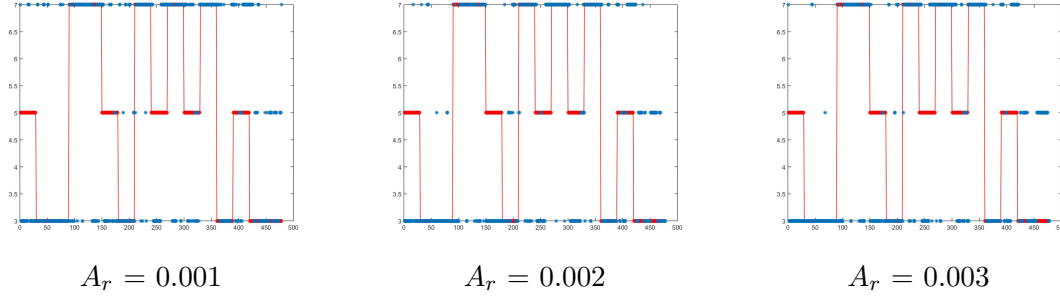


Figura G.9: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 9. Diferentes  $A_r$

Tabla G.18: Niveles de precisión alcanzados para los datos EmoExt Sujeto 9 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 9					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	50.42	71.97	5.37	65.92	76.67
0.002	50.84	78.87	7.38	67.60	74.00
0.003	52.72	79.71	5.37	72.63	76.00

Tabla G.19: Matriz de confusión para los datos EmoExt Sujeto 9 para diferentes valores de  $A_r$

EmoExt Sujeto 9			
$A_r = 0.001$			
<b>50.42</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	118	22	39
Real Derecha	81	8	60
Real Palabra	33	2	115
$A_r = 0.002$			
<b>50.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	121	34	24
Real Derecha	100	11	38
Real Palabra	36	3	111
$A_r = 0.003$			
<b>52.72</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	110	34	15
Real Derecha	95	8	46
Real Palabra	35	1	114



## EmoExt Sujeto 10

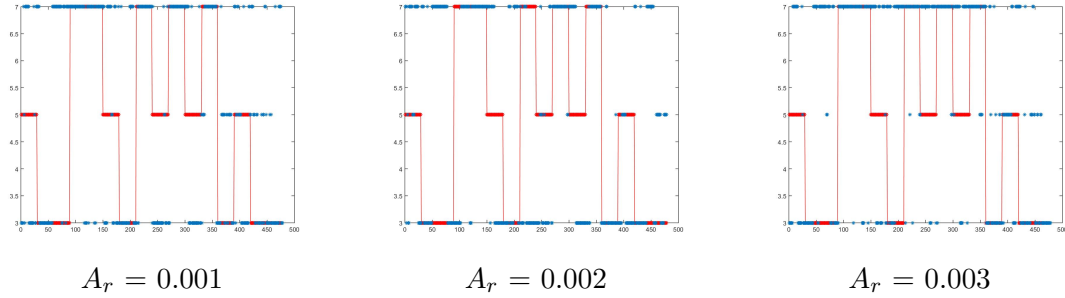


Figura G.10: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 10. Diferentes  $A_r$

Tabla G.20: Niveles de precisión alcanzados para los datos EmoExt Sujeto 10 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 10					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	51.05	74.90	10.00	56.67	85.81
0.002	45.19	66.32	10.67	56.67	66.22
0.003	51.67	64.44	12.67	54.44	87.84

Tabla G.21: Matriz de confusión para los datos EmoExt Sujeto 10 para diferentes valores de  $A_r$

EmoExt Sujeto 10			
$A_r = 0.001$			
<b>51.05</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	118	22	39
Real Derecha	81	8	60
Real Palabra	33	2	115
$A_r = 0.002$			
<b>45.19</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	121	34	24
Real Derecha	100	11	38
Real Palabra	36	3	111
$A_r = 0.003$			
<b>51.67</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	110	34	15
Real Derecha	95	8	46
Real Palabra	35	1	114

## EmoExt Sujeto 11

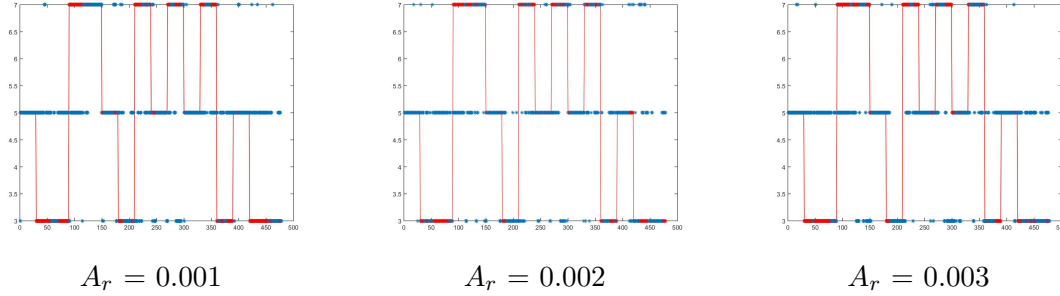


Figura G.11: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 11. Diferentes  $A_r$

Tabla G.22: Niveles de precisión alcanzados para los datos EmoExt Sujeto 11 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 11					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	45.19	75.10	81.88	23.46	34.67
0.002	50.00	72.38	80.54	43.02	28.00
0.003	47.49	74.48	81.21	36.87	26.67

Tabla G.23: Matriz de confusión para los datos EmoExt Sujeto 11 para diferentes valores de  $A_r$

EmoExt Sujeto 11			
$A_r = 0.001$			
<b>45.19</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	42	129	8
Real Derecha	14	122	13
Real Palabra	25	73	52
$A_r = 0.002$			
<b>50.00</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	77	89	13
Real Derecha	18	120	11
Real Palabra	28	80	42
$A_r = 0.003$			
<b>47.49</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	66	110	3
Real Derecha	19	121	9
Real Palabra	38	72	40

## EmoExt Sujeto 12

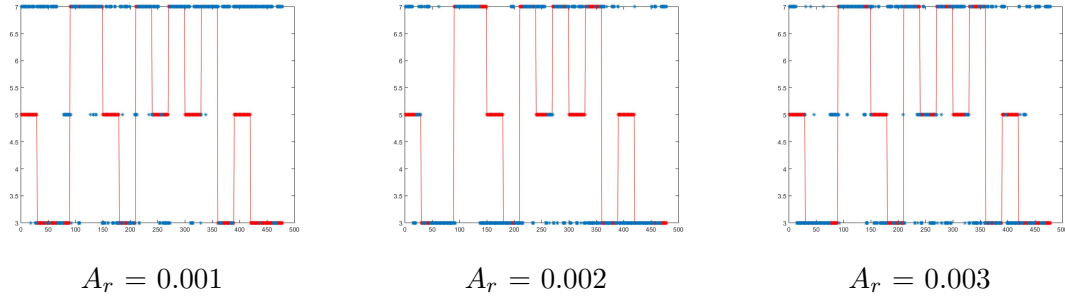


Figura G.12: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 12. Diferentes  $A_r$

Tabla G.24: Niveles de precisión alcanzados para los datos EmoExt Sujeto 12 para diferentes valores de  $A_r$  mostrados como %

EmoExt Sujeto 12					
Valor $A_r$	Global	Motor	Derecha	Izquierda	Palabra
0.001	36.40	48.33	2.68	25.70	82.67
0.002	48.12	65.27	9.40	71.51	58.67
0.003	40.79	61.72	14.09	47.49	59.33

Tabla G.25: Matriz de confusión para los datos EmoExt Sujeto 12 para diferentes valores de  $A_r$

EmoExt Sujeto 12			
$A_r = 0.001$			
<b>36.40</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	46	15	118
Real Derecha	42	4	103
Real Palabra	12	14	124
$A_r = 0.002$			
<b>48.12</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	128	0	51
Real Derecha	82	14	53
Real Palabra	61	1	88
$A_r = 0.003$			
<b>40.79</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	85	24	70
Real Derecha	76	21	52
Real Palabra	45	16	89



## Apéndice H

# Resultados S-dFasArt - Base de Datos EmoExt - Comparativa PSD

Las siguientes tablas muestran los resultados obtenidos para cada Sujeto para diferentes mecanismos de cálculo de la PSD mateniendo parámetro velocidad de reset  $A_r = 0.002$ .

Tabla H.1: Datos capturados con Emotiv EPOC. Base de datos Extendida. Comparativa acierto entre usuarios y algoritmos de cálculo de la PSD.  $A_r=0.002$ . Tasa de acierto en %

	Tasa de acierto (%)					
	PWelch 50 % Overlap	PWelch No Overlap	Periodogram	Periodogram	PWelch 50 % Overlap	PWelch No Overlap
	Hamming	Hamming	Hamming	Hanning	Hanning	Hanning
EmoExt S1	<b>67.57</b>	65.27	46.44	47.49	47.49	47.49
EmoExt S2	<b>62.76</b>	58.62	50.86	53.66	53.97	51.46
EmoExt S3	<b>62.55</b>	50.63	50.21	56.07	56.07	56.07
EmoExt S4	<b>61.09</b>	53.77	44.98	45.19	45.19	45.19
EmoExt S6	<b>56.49</b>	54.21	45.57	52.05	45.61	41.00
EmoExt S7	<b>55.02</b>	50.63	28.66	30.75	30.75	30.75
EmoExt S8	<b>53.56</b>	29.08	36.19	37.03	37.03	37.03
EmoExt S9	<b>50.84</b>	47.70	35.98	32.43	32.43	32.43
EmoExt S11	<b>50.00</b>	37.66	49.58	41.84	41.84	41.84
EmoExt S5	<b>49.79</b>	35.15	48.33	46.86	46.86	46.86
EmoExt S12	<b>48.12</b>	31.80	37.03	33.89	33.89	33.89
EmoExt S10	<b>45.19</b>	36.82	25.31	42.26	42.26	42.26
<b>Media</b>	54.57	44.79	40.75	42.35	41.77	41.35

## EmoExt Sujeto 1

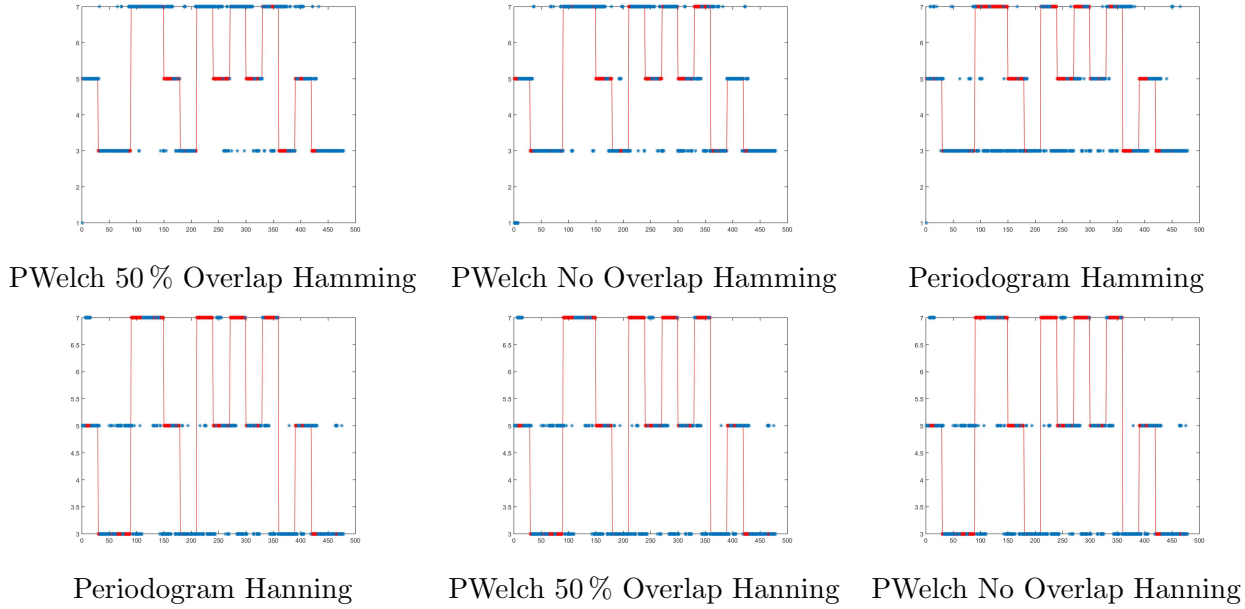


Figura H.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 1. Diferentes PSD

Tabla H.2: Niveles de precisión alcanzados para los datos EmoExt Sujeto 1 para diferentes variantes del cálculo de la PSD mostrados como %

EmoExt Sujeto 1					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	67.57	75.73	40.67	73.74	87.25
PWelch No Overlap Hamming	65.27	75.52	46.67	76.54	70.47
Periodogram Hamming	46.44	69.04	38.00	69.27	27.52
Periodogram Hanning	47.49	70.92	46.67	70.39	20.81
PWelch 50 % Overlap Hanning	47.49	70.92	46.67	70.39	20.81
PWelch No Overlap Hanning	47.49	70.92	46.67	70.39	20.81

Tabla H.3: Matriz de confusión para los datos EmoExt Sujeto 1 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 1</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>67.57</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	132	10	37
Real Derecha	29	61	59
Real Palabra	18	1	130
<b>PWelch No Overlap Hamming</b>			
<b>65.27</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	137	17	25
Real Derecha	32	70	40
Real Palabra	32	12	105
<b>Periodogram Hamming</b>			
<b>47.49</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	124	26	29
Real Derecha	82	57	10
Real Palabra	86	22	41
<b>Periodogram Hanning</b>			
<b>47.49</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	126	53	0
Real Derecha	59	70	21
Real Palabra	77	41	31
<b>PWelch 50 % Overlap Hanning</b>			
<b>47.49</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	126	53	0
Real Derecha	59	70	21
Real Palabra	77	41	31
<b>PWelch No Overlap Hanning</b>			
<b>61.51</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	126	53	0
Real Derecha	59	70	21
Real Palabra	77	41	31

## EmoExt Sujeto 2

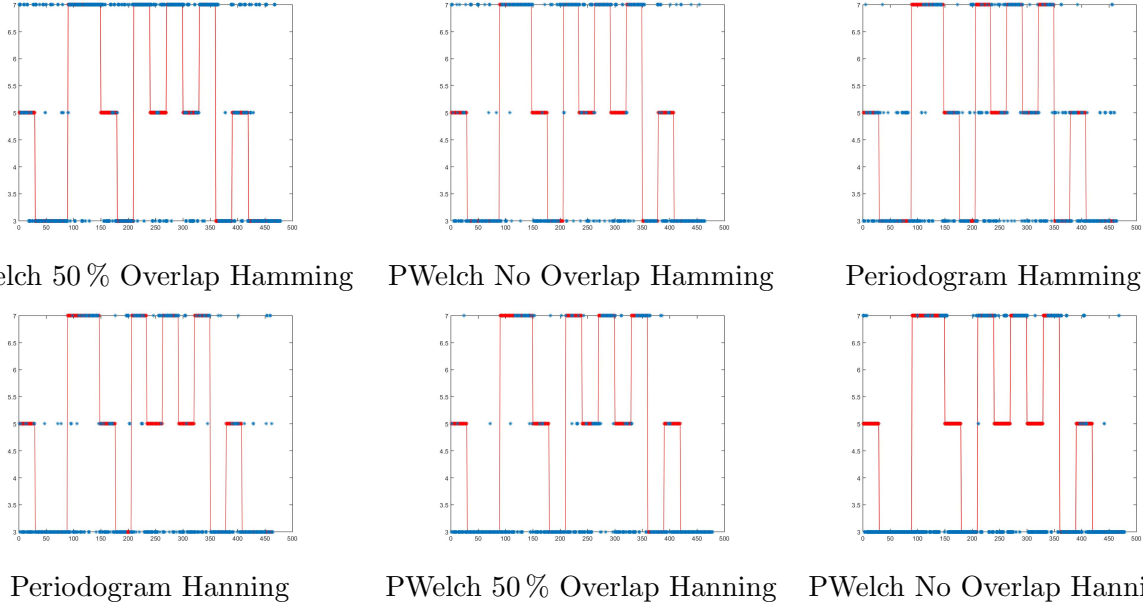


Figura H.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 2. Diferentes PSD

Tabla H.4: Niveles de precisión alcanzados para los datos EmoExt Sujeto 2 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 2					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	62.76	75.31	27.52	70.39	88.67
PWelch No Overlap Hamming	58.62	77.80	13.10	78.16	80.69
Periodogram Hamming	50.86	75.43	40.69	66.67	42.07
Periodogram Hanning	55.36	78.66	17.93	87.36	48.97
PWelch 50 % Overlap Hanning	53.97	78.45	17.45	94.41	42.00
PWelch No Overlap Hanning	51.46	76.36	3.36	94.41	48.00



Tabla H.5: Matriz de confusión para los datos EmoExt Sujeto 2 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 2</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>62.76</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	126	8	45
Real Derecha	52	41	56
Real Palabra	16	1	133
<b>PWelch No Overlap Hamming</b>			
<b>58.62</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	136	2	36
Real Derecha	87	19	39
Real Palabra	11	6	117
<b>Periodogram Hamming</b>			
<b>50.86</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	116	46	12
Real Derecha	68	59	18
Real Palabra	63	21	61
<b>Periodogram Hanning</b>			
<b>55.36</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	152	10	12
Real Derecha	106	26	13
Real Palabra	66	8	71
<b>PWelch 50 % Overlap Hanning</b>			
<b>53.97</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	169	1	9
Real Derecha	116	26	7
Real Palabra	73	14	63
<b>PWelch No Overlap Hanning</b>			
<b>51.46</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	169	1	9
Real Derecha	118	5	26
Real Palabra	77	1	72

### EmoExt Sujeto 3

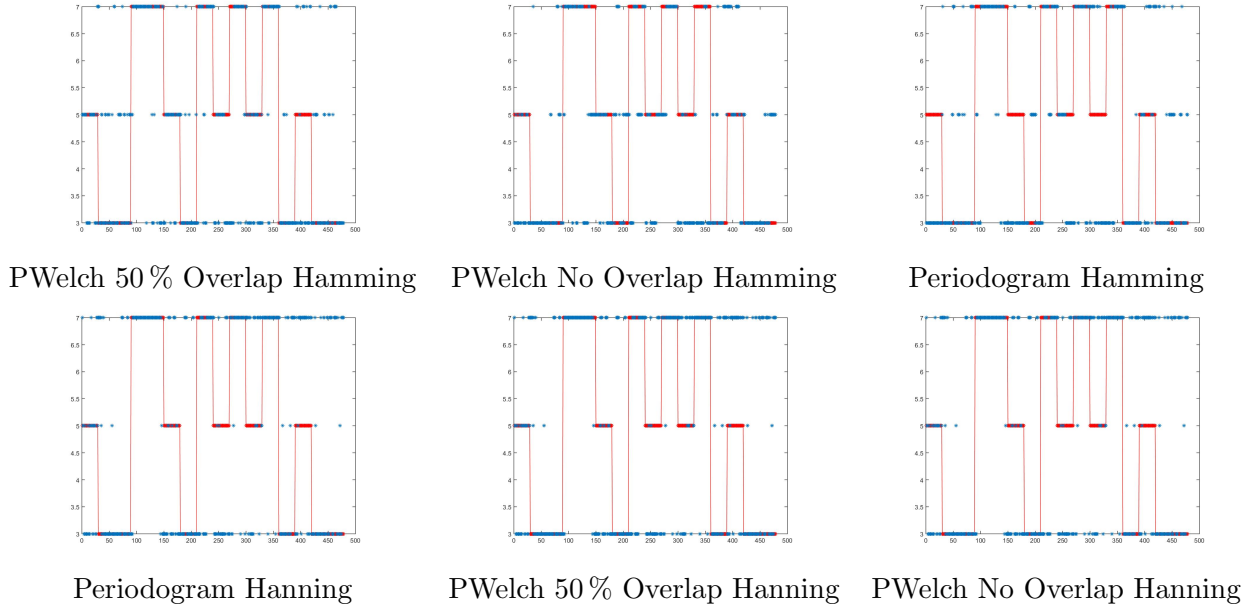


Figura H.3: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 3. Diferentes PSD

Tabla H.6: Niveles de precisión alcanzados para los datos EmoExt Sujeto 3 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 3					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	62.55	89.94	44.30	69.83	72.00
PWelch No Overlap Hamming	50.63	76.15	37.58	65.92	45.33
Periodogram Hamming	50.21	78.24	15.44	67.60	64.00
Periodogram Hanning	56.07	71.79	16.78	68.16	80.67
PWelch 50 % Overlap Hanning	56.07	71.79	16.78	68.16	80.67
PWelch No Overlap Hanning	56.07	71.79	16.78	68.16	80.67

Tabla H.7: Matriz de confusión para los datos EmoExt Sujeto 3 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 3</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>62.55</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	125	38	16
Real Derecha	69	66	14
Real Palabra	33	9	108
<b>PWelch No Overlap Hamming</b>			
<b>50.63</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	118	44	17
Real Derecha	78	56	15
Real Palabra	46	36	69
<b>Periodogram Hamming</b>			
<b>50.21</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	121	33	25
Real Derecha	101	23	25
Real Palabra	44	10	96
<b>Periodogram Hanning</b>			
<b>56.07</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	122	6	51
Real Derecha	70	25	54
Real Palabra	27	2	121
<b>PWelch 50 % Overlap Hanning</b>			
<b>56.07</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	122	6	51
Real Derecha	70	25	54
Real Palabra	27	2	121
<b>PWelch No Overlap Hanning</b>			
<b>56.07</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	122	6	51
Real Derecha	70	25	54
Real Palabra	27	2	121

## EmoExt Sujeto 4

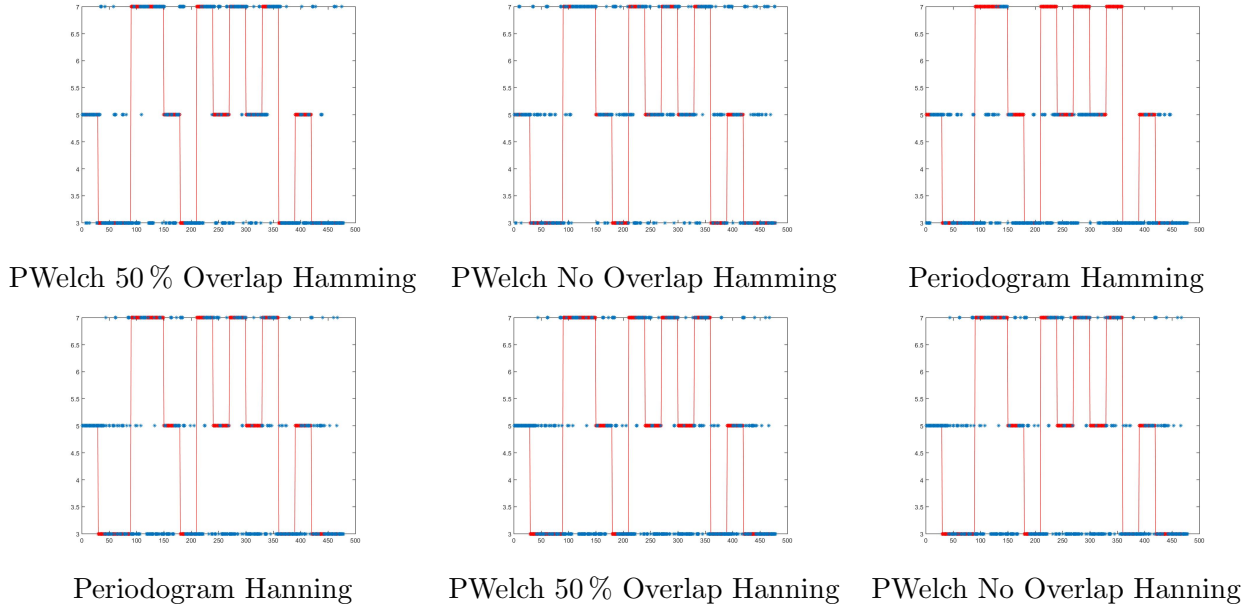


Figura H.4: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 4. Diferentes PSD

Tabla H.8: Niveles de precisión alcanzados para los datos EmoExt Sujeto 4 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 4					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	61.09	77.62	41.61	77.09	61.33
PWelch No Overlap Hamming	53.77	73.43	61.74	40.78	61.33
Periodogram Hamming	44.98	71.76	37.58	80.45	10.00
Periodogram Hanning	45.19	71.55	38.93	59.78	34.00
PWelch 50 % Overlap Hanning	45.19	71.55	38.93	59.78	34.00
PWelch No Overlap Hanning	45.19	71.55	38.93	59.78	34.00

Tabla H.9: Matriz de confusión para los datos EmoExt Sujeto 4 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 4</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>61.09</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	138	15	26
Real Derecha	64	62	23
Real Palabra	44	14	92
<b>PWelch No Overlap Hamming</b>			
<b>53.77</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	73	66	40
Real Derecha	28	92	29
Real Palabra	27	31	92
<b>Periodogram Hamming</b>			
<b>44.98</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	144	35	0
Real Derecha	93	56	0
Real Palabra	84	51	15
<b>Periodogram Hanning</b>			
<b>45.19</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	107	53	19
Real Derecha	73	58	18
Real Palabra	84	15	51
<b>PWelch 50 % Overlap Hanning</b>			
<b>45.19</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	107	53	19
Real Derecha	73	58	18
Real Palabra	84	15	51
<b>PWelch No Overlap Hanning</b>			
<b>45.19</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	107	53	19
Real Derecha	73	58	18
Real Palabra	84	15	51

## EmoExt Sujeto 5

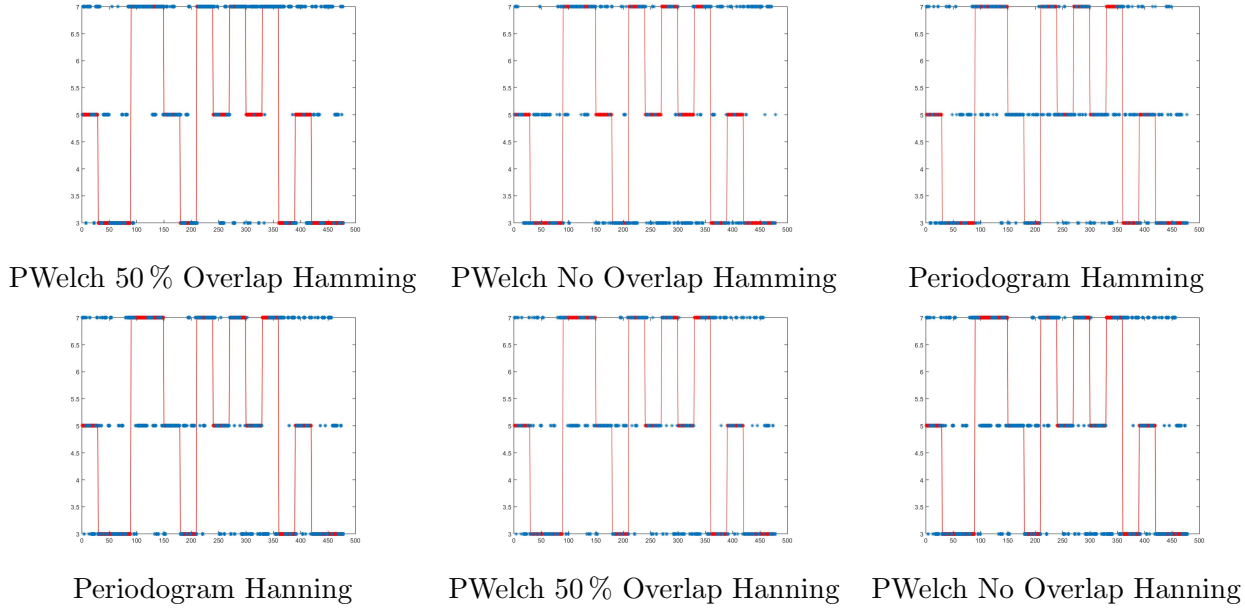


Figura H.5: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 5. Diferentes PSD

Tabla H.10: Niveles de precisión alcanzados para los datos EmoExt Sujeto 5 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 5					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	49.79	65.69	26.85	40.22	84.00
PWelch No Overlap Hamming	35.15	61.92	17.45	37.43	50.00
Periodogram Hamming	48.33	72.18	57.72	42.46	46.00
Periodogram Hanning	46.86	65.84	53.69	40.78	47.33
PWelch 50 % Overlap Hanning	46.86	65.84	53.69	40.78	47.33
PWelch No Overlap Hanning	46.86	65.84	53.69	40.78	47.33

Tabla H.11: Matriz de confusión para los datos EmoExt Sujeto 5 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 5</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>49.79</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	72	44	63
Real Derecha	32	40	77
Real Palabra	13	11	126
<b>PWelch No Overlap Hamming</b>			
<b>35.15</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	67	45	67
Real Derecha	83	26	40
Real Palabra	51	24	75
<b>Periodogram Hamming</b>			
<b>48.33</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	76	70	33
Real Derecha	44	86	19
Real Palabra	22	59	69
<b>Periodogram Hanning</b>			
<b>46.86</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	73	43	63
Real Derecha	43	80	26
Real Palabra	43	36	71
<b>PWelch 50 % Overlap Hanning</b>			
<b>46.86</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	73	43	63
Real Derecha	43	80	26
Real Palabra	43	36	71
<b>PWelch No Overlap Hanning</b>			
<b>46.86</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	73	43	63
Real Derecha	43	80	26
Real Palabra	43	36	71

## EmoExt Sujeto 6

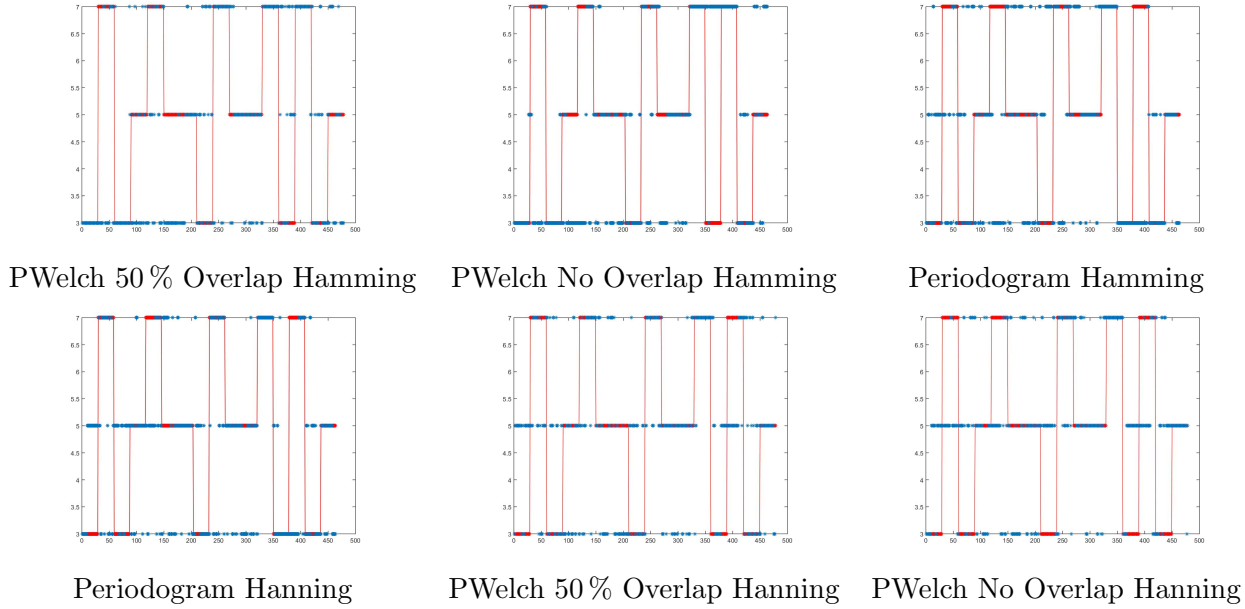


Figura H.6: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 6. Diferentes PSD

Tabla H.12: Niveles de precisión alcanzados para los datos EmoExt Sujeto 6 para diferentes variantes del cálculo de la de PSD mostrados como %


EmoExt Sujeto 6					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	56.49	79.71	41.90	61.74	68.74
PWelch No Overlap Hamming	54.21	76.67	40.46	62.76	62.07
Periodogram Hamming	45.57	64.36	46.24	55.86	34.48
Periodogram Hanning	52.05	78.40	57.80	49.66	47.59
PWelch 50 % Overlap Hanning	45.61	75.73	45.25	37.58	54.00
PWelch No Overlap Hanning	41.00	70.29	58.66	20.81	40.00




Tabla H.13: Matriz de confusión para los datos EmoExt Sujeto 6 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 6</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>56.49</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	92	27	30
Real Derecha	84	75	20
Real Palabra	37	10	103
<b>PWelch No Overlap Hamming</b>			
<b>54.21</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	91	24	30
Real Derecha	80	70	23
Real Palabra	46	9	90
<b>Periodogram Hamming</b>			
<b>45.57</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	8 1	41	23
Real Derecha	46	80	47
Real Palabra	73	22	50
<b>Periodogram Hanning</b>			
<b>52.05</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	72	67	6
Real Derecha	55	100	18
Real Palabra	44	32	69
<b>PWelch 50 % Overlap Hanning</b>			
<b>45.61</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	56	71	33
Real Derecha	73	81	25
Real Palabra	12	57	81
<b>PWelch No Overlap Hanning</b>			
<b>41.00</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	31	97	21
Real Derecha	43	105	31
Real Palabra	18	72	60


## EmoExt Sujeto 7




PWelch 50 % Overlap Hamming




PWelch No Overlap Hamming




Periodogram Hamming



Periodogram Hanning



PWelch 50 % Overlap Hanning



PWelch No Overlap Hanning

Figura H.7: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 7. Diferentes PSD


Tabla H.14: Niveles de precisión alcanzados para los datos EmoExt Sujeto 7 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 7					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	55.02	73.01	13.42	82.12	64.00
PWelch No Overlap Hamming	50.63	75.94	11.41	80.45	54.00
Periodogram Hamming	28.66	45.19	18.12	29.61	38.00
Periodogram Hanning	30.75	58.37	31.54	21.79	40.67
PWelch 50 % Overlap Hanning	30.75	58.37	31.54	21.79	40.67
PWelch No Overlap Hanning	30.75	58.37	31.54	21.79	40.67


Tabla H.15: Matriz de confusión para los datos EmoExt Sujeto 7 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 7</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>55.02</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	147	10	33
Real Derecha	76	20	53
Real Palabra	50	4	96
<b>PWelch No Overlap Hamming</b>			
<b>50.63</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	144	22	13
Real Derecha	99	17	33
Real Palabra	36	33	81
<b>Periodogram Hamming</b>			
<b>28.66</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	53	19	107
Real Derecha	60	27	62
Real Palabra	43	50	57
<b>Periodogram Hanning</b>			
<b>30.75</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	39	77	63
Real Derecha	55	47	47
Real Palabra	23	66	61
<b>PWelch 50 % Overlap Hanning</b>			
<b>30.75</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	39	77	63
Real Derecha	55	47	47
Real Palabra	23	66	61
<b>PWelch No Overlap Hanning</b>			
<b>30.75</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	39	77	63
Real Derecha	55	47	47
Real Palabra	23	66	61


## EmoExt Sujeto 8




PWelch 50 % Overlap Hamming




PWelch No Overlap Hamming




Periodogram Hamming



Periodogram Hanning



PWelch 50 % Overlap Hanning



PWelch No Overlap Hanning

Figura H.8: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 8. Diferentes PSD

Tabla H.16: Niveles de precisión alcanzados para los datos EmoExt Sujeto 8 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 8					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	53.56	76.99	4.76	94.48	52.00
PWelch No Overlap Hamming	29.08	69.25	24.49	40.33	20.00
Periodogram Hamming	36.19	62.97	2.04	70.72	28.00
Periodogram Hanning	37.03	69.25	24.49	50.83	32.67
PWelch 50 % Overlap Hanning	37.03	69.25	24.49	50.83	32.67
PWelch No Overlap Hanning	37.03	69.25	24.49	50.83	32.67

Tabla H.17: Matriz de confusión para los datos EmoExt Sujeto 8 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 8</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>53.56</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	171	1	9
Real Derecha	111	7	29
Real Palabra	66	6	78
<b>PWelch No Overlap Hamming</b>			
<b>29.08</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	73	95	13
Real Derecha	97	36	14
Real Palabra	56	64	30
<b>Periodogram Hamming</b>			
<b>36.19</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	128	3	50
Real Derecha	125	3	19
Real Palabra	108	0	42
<b>Periodogram Hanning</b>			
<b>37.03</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	92	70	19
Real Derecha	84	36	27
Real Palabra	91	10	49
<b>PWelch 50 % Overlap Hanning</b>			
<b>37.03</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	92	70	19
Real Derecha	84	36	27
Real Palabra	91	10	49
<b>PWelch No Overlap Hanning</b>			
<b>37.03</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	92	70	19
Real Derecha	84	36	27
Real Palabra	91	10	49

## EmoExt Sujeto 9

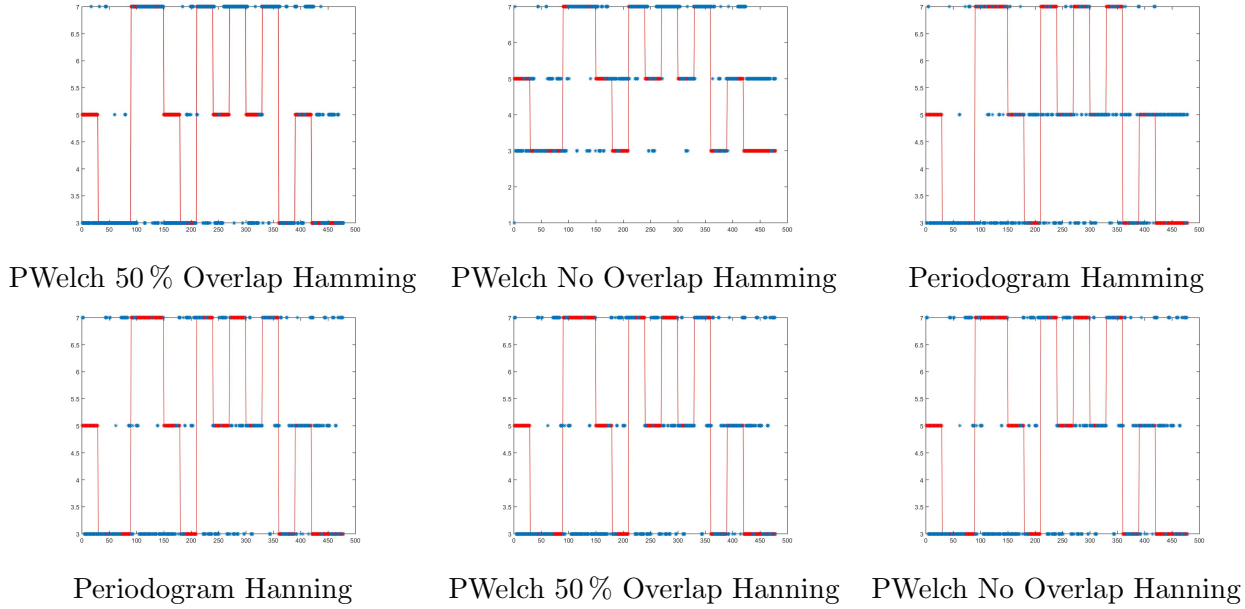


Figura H.9: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 9. Diferentes PSD

Tabla H.18: Niveles de precisión alcanzados para los datos EmoExt Sujeto 9 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 9					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	50.84	78.87	7.38	67.60	74.00
PWelch No Overlap Hamming	47.70	79.92	36.91	28.49	81.33
Periodogram Hamming	35.98	70.50	41.61	43.58	21.33
Periodogram Hanning	32.43	58.37	33.56	36.31	26.67
PWelch 50 % Overlap Hanning	32.43	58.37	33.56	36.31	26.67
PWelch No Overlap Hanning	32.43	58.37	33.56	36.31	26.67

Tabla H.19: Matriz de confusión para los datos EmoExt Sujeto 9 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 9</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>50.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	121	34	24
Real Derecha	100	11	38
Real Palabra	36	3	111
<b>PWelch No Overlap Hamming</b>			
<b>47.70</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	51	111	17
Real Derecha	43	55	50
Real Palabra	15	13	122
<b>Periodogram Hamming</b>			
<b>35.98</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	78	91	10
Real Derecha	74	62	13
Real Palabra	71	47	32
<b>Periodogram Hanning</b>			
<b>32.43</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	65	51	63
Real Derecha	73	50	26
Real Palabra	76	34	40
<b>PWelch 50 % Overlap Hanning</b>			
<b>32.43</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	65	51	63
Real Derecha	73	50	26
Real Palabra	76	34	40
<b>PWelch No Overlap Hanning</b>			
<b>32.43</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	65	51	63
Real Derecha	73	50	26
Real Palabra	76	34	40

## EmoExt Sujeto 10

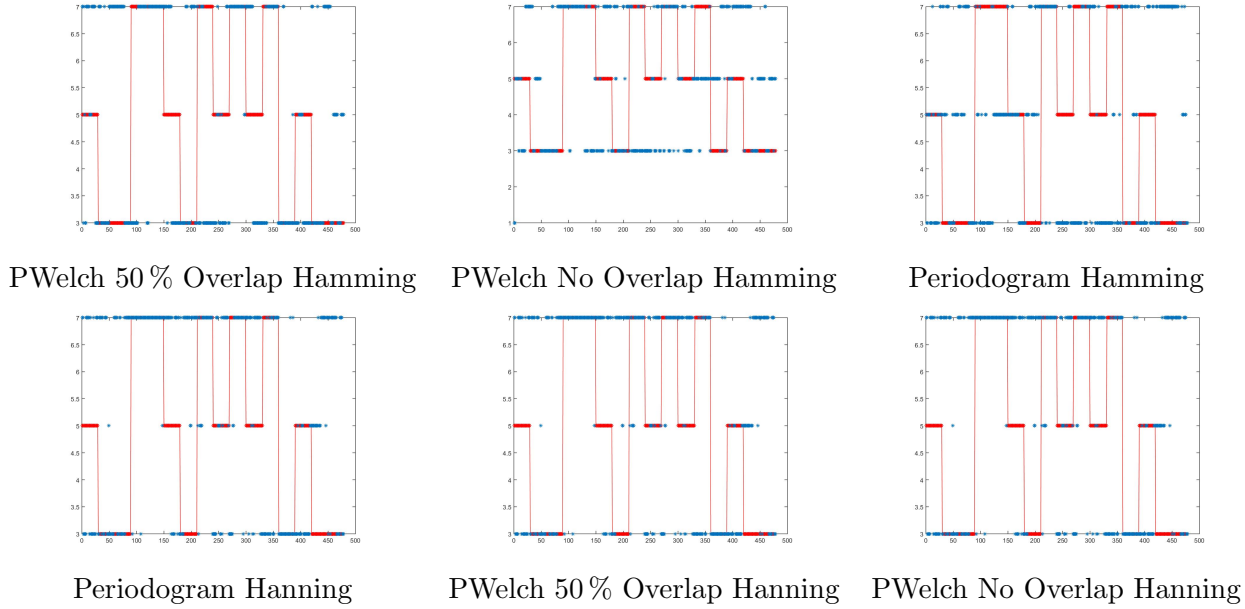


Figura H.10: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 10. Diferentes PSD

Tabla H.20: Niveles de precisión alcanzados para los datos EmoExt Sujeto 10 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 10					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	45.19	66.32	10.67	56.67	66.22
PWelch No Overlap Hamming	36.82	60.04	21.33	39.44	49.32
Periodogram Hamming	25.31	54.18	20.00	30.41	31.41
Periodogram Hanning	42.26	59.62	10.00	41.11	76.35
PWelch 50 % Overlap Hanning	42.26	59.62	10.00	41.11	76.35
PWelch No Overlap Hanning	42.26	59.62	10.00	41.11	76.35



Tabla H.21: Matriz de confusión para los datos EmoExt Sujeto 10 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 10</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>45.19</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	102	14	64
Real Derecha	87	16	47
Real Palabra	48	2	98
<b>PWelch No Overlap Hamming</b>			
<b>36.82</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	71	57	52
Real Derecha	54	32	62
Real Palabra	47	28	73
<b>Periodogram Hamming</b>			
<b>25.31</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	46	45	89
Real Derecha	93	30	27
Real Palabra	68	35	45
<b>Periodogram Hanning</b>			
<b>42.26</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	74	20	86
Real Derecha	63	15	72
Real Palabra	27	8	113
<b>PWelch 50 % Overlap Hanning</b>			
<b>42.26</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	74	20	86
Real Derecha	63	15	72
Real Palabra	27	8	113
<b>PWelch No Overlap Hanning</b>			
<b>42.26</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	74	20	86
Real Derecha	63	15	72
Real Palabra	27	8	113

## EmoExt Sujeto 11

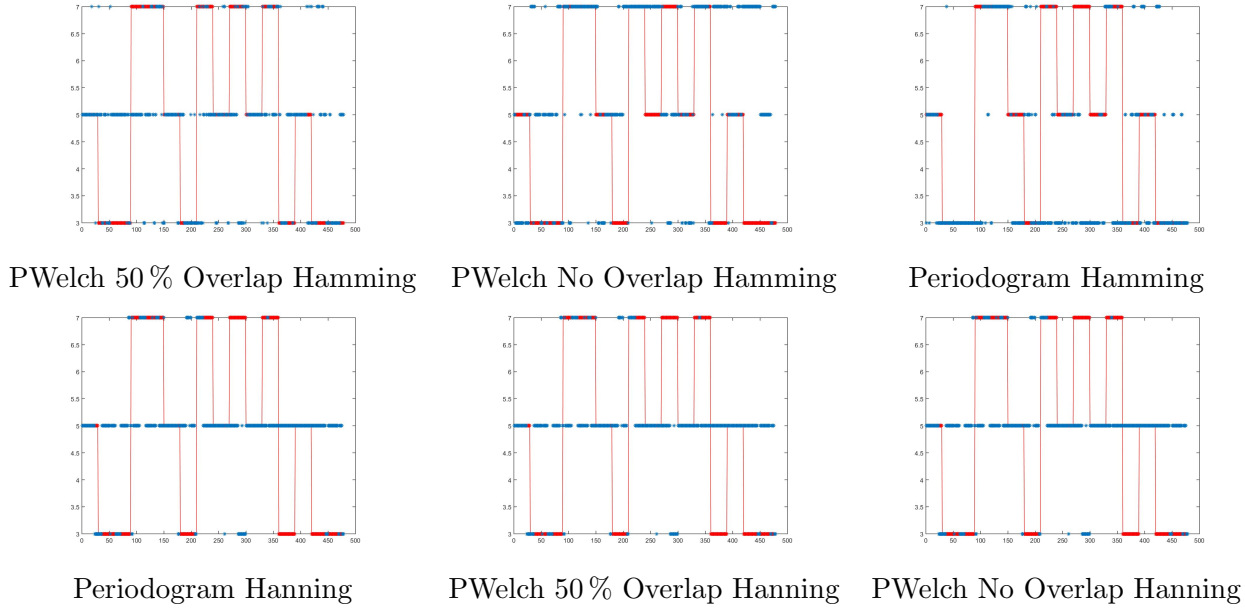


Figura H.11: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 11. Diferentes PSD

Tabla H.22: Niveles de precisión alcanzados para los datos EmoExt Sujeto 11 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 11					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	50.00	72.38	80.54	43.02	28.00
PWelch No Overlap Hamming	37.66	62.34	34.23	11.73	72.00
Periodogram Hamming	49.58	73.85	32.89	73.74	37.33
Periodogram Hanning	41.84	72.59	93.29	16.20	21.33
PWelch 50 % Overlap Hanning	41.84	72.59	93.29	16.20	21.33
PWelch No Overlap Hanning	41.84	72.59	93.29	16.20	21.33

Tabla H.23: Matriz de confusión para los datos EmoExt Sujeto 11 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 11</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>50.00</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	77	89	13
Real Derecha	18	120	11
Real Palabra	28	80	42
<b>PWelch No Overlap Hamming</b>			
<b>37.66</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	21	70	88
Real Derecha	48	51	50
Real Palabra	17	25	108
<b>Periodogram Hamming</b>			
<b>49.58</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	132	31	16
Real Derecha	85	49	15
Real Palabra	81	13	56
<b>Periodogram Hanning</b>			
<b>41.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	29	138	12
Real Derecha	9	139	1
Real Palabra	15	103	32
<b>PWelch 50 % Overlap Hanning</b>			
<b>41.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	29	138	12
Real Derecha	9	139	1
Real Palabra	15	103	32
<b>PWelch No Overlap Hanning</b>			
<b>41.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	29	138	12
Real Derecha	9	139	1
Real Palabra	15	103	32

## EmoExt Sujeto 12

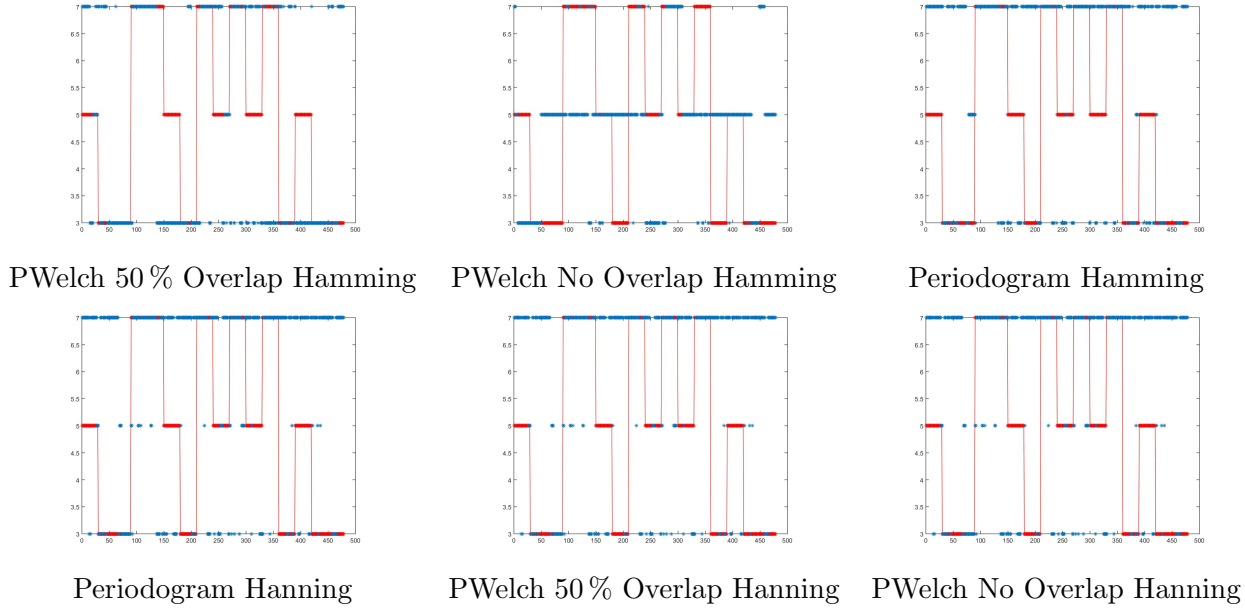


Figura H.12: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 12. Diferentes PSD

Tabla H.24: Niveles de precisión alcanzados para los datos EmoExt Sujeto 12 para diferentes variantes del cálculo de la de PSD mostrados como %

EmoExt Sujeto 12					
Variante Cálculo PSD	Global	Motor	Derecha	Izquierda	Palabra
PWelch 50 % Overlap Hamming	48.12	65.27	9.40	71.51	58.67
PWelch No Overlap Hamming	31.80	71.13	55.03	18.99	24.00
Periodogram Hamming	37.03	48.95	0.67	27.93	84.00
Periodogram Hanning	33.89	42.68	4.70	22.91	76.00
PWelch 50 % Overlap Hanning	33.89	42.68	4.70	22.91	76.00
PWelch No Overlap Hanning	33.89	42.68	4.70	22.91	76.00

Tabla H.25: Matriz de confusión para los datos EmoExt Sujeto 12 para diferentes variantes del cálculo de la de PSD

<b>EmoExt Sujeto 12</b>			
<b>PWelch 50 % Overlap Hamming</b>			
<b>50.00</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	128	0	51
Real Derecha	82	14	53
Real Palabra	61	1	88
<b>PWelch No Overlap Hamming</b>			
<b>37.66</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	34	134	11
Real Derecha	54	82	13
Real Palabra	18	96	36
<b>Periodogram Hamming</b>			
<b>49.58</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	50	17	112
Real Derecha	40	1	108
Real Palabra	23	1	126
<b>Periodogram Hanning</b>			
<b>41.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	41	10	128
Real Derecha	32	7	110
Real Palabra	20	16	114
<b>PWelch 50 % Overlap Hanning</b>			
<b>41.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	41	10	128
Real Derecha	32	7	110
Real Palabra	20	16	114
<b>PWelch No Overlap Hanning</b>			
<b>41.84</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	41	10	128
Real Derecha	32	7	110
Real Palabra	20	16	114



## Apéndice I

# Resultados S-dFasArt - Realimentación

Las siguientes tablas muestran los resultados obtenidos para escenarios con realimentación limitados a un solo sujeto.

## Prueba 1

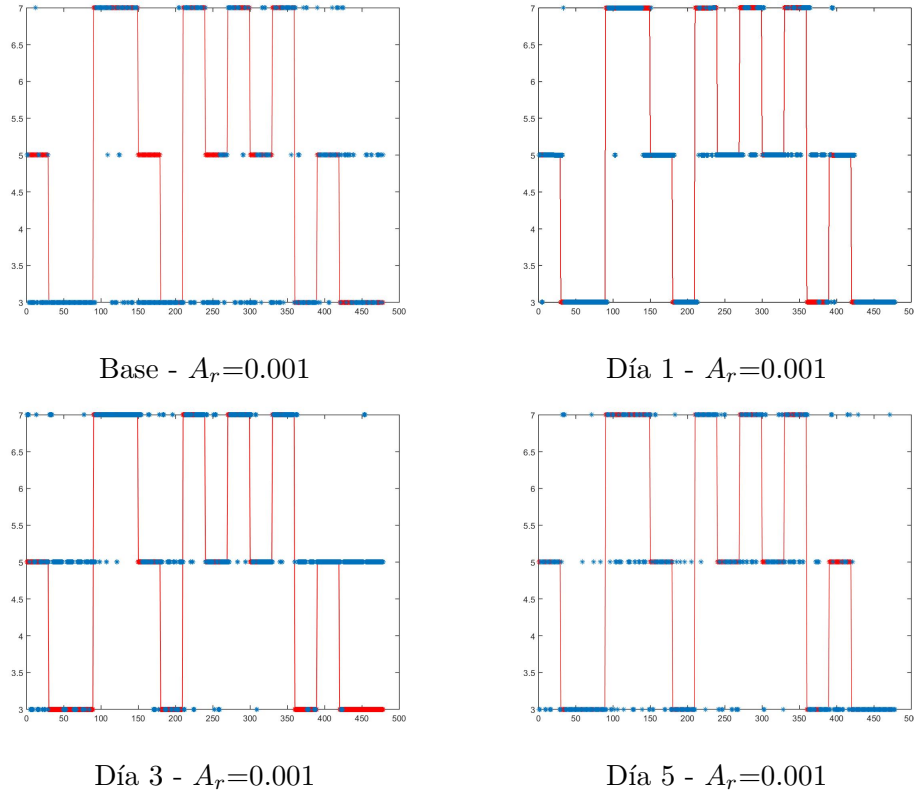


Figura I.1: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos Prueba 1 realimentación

Tabla I.1: Datos capturados con Emotiv EPOC. Prueba 1 con realimentación. Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra	Modelo Base
<b>Prueba 1</b>						
Base	58.37	82.85	32.21	79.33	59.33	
Día 1	76.99	83.89	91.95	81.01	57.33	Día 0
Día 3	55.86	88.28	69.13	19.55	86.00	Día 1
Día 5	66.95	79.92	53.69	86.03	57.33	Día 0



Tabla I.2: Matriz de confusión para los datos Emotiv EPOC para diferentes experimentos consecutivos con realimentacion

<b>Sujeto 1</b>			
<b>Base</b>			
<b>58.37</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	142	27	10
Real Derecha	90	48	11
Real Palabra	55	6	89
<b>Día 1</b>			
<b>76.99</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	145	28	6
Real Derecha	5	137	7
Real Palabra	7	57	86
<b>Día 3</b>			
<b>55.86</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	35	131	13
Real Derecha	24	103	22
Real Palabra	4	17	129
<b>Día 5</b>			
<b>66.95</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	154	15	10
Real Derecha	47	80	22
Real Palabra	15	49	86

## Prueba 2

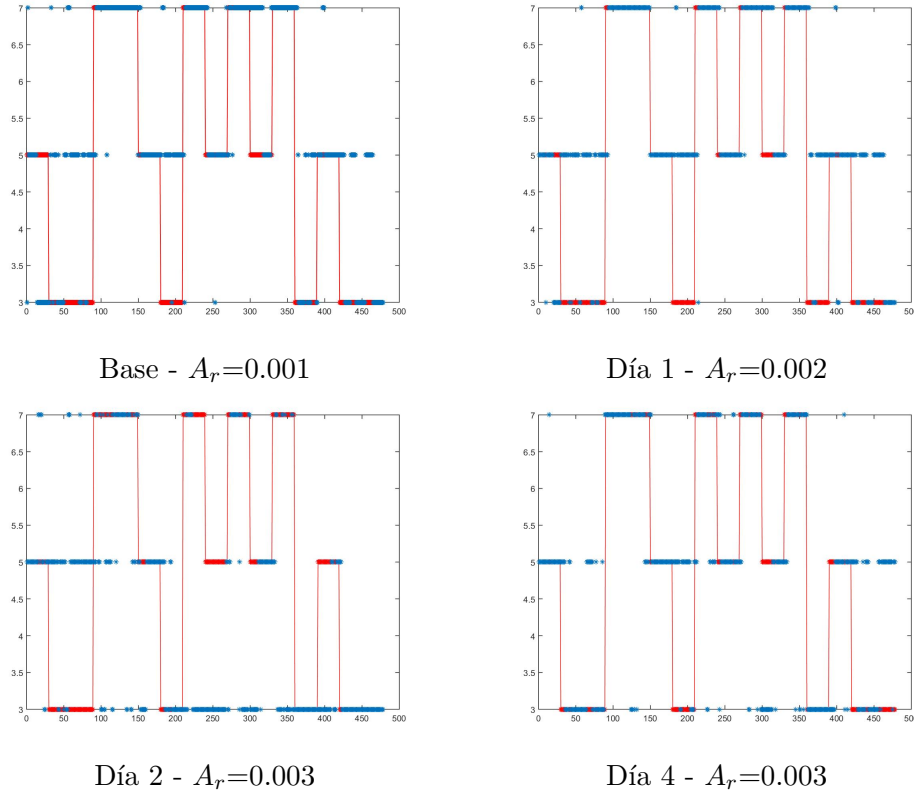


Figura I.2: Representación gráfica de los resultados de la clasificación en función de la tarea objetivo: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos Prueba 2 realimentación

Tabla I.3: Datos capturados con Emotiv EPOC. Prueba 2 con realimentación. Comparativa basada en la tasa de acierto en %

	Global	Motor	Derecha	Izquierda	Palabra	Modelo Base
<b>Prueba 2</b>						
Base	64.44	88.49	65.77	39.66	92.67	
Día 1	73.85	92.68	78.52	60.89	84.67	Día 0
Día 2	51.26	79.08	47.97	63.89	39.33	Día 1
Día 4	68.62	89.75	75.84	56.98	75.33	Día 0

Tabla I.4: Matriz de confusión para los datos Emotiv EPOC para diferentes experimentos consecutivos con realimentacion

<b>Sujeto 2</b>			
<b>Base</b>			
<b>64.44</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	71	96	12
Real Derecha	19	98	32
Real Palabra	1	10	139
<b>Día 1</b>			
<b>73.85</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	109	68	2
Real Derecha	22	117	10
Real Palabra	6	17	127
<b>Día 3</b>			
<b>51.26</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	115	61	4
Real Derecha	72	71	5
Real Palabra	64	27	59
<b>Día 5</b>			
<b>68.62</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	107	75	2
Real Derecha	26	113	10
Real Palabra	16	21	113



## Apéndice J

# Resultados Selección de Características. Base de Datos BCIComp

Las siguientes tablas muestran los las tasas de acierto por valores de acierto por tarea y el comportamiento de éstos gráficamente. También se han incluido las matrices de confusión para un mejor entendimiento de los resultados presentados.

## BCIComp Sujeto 1

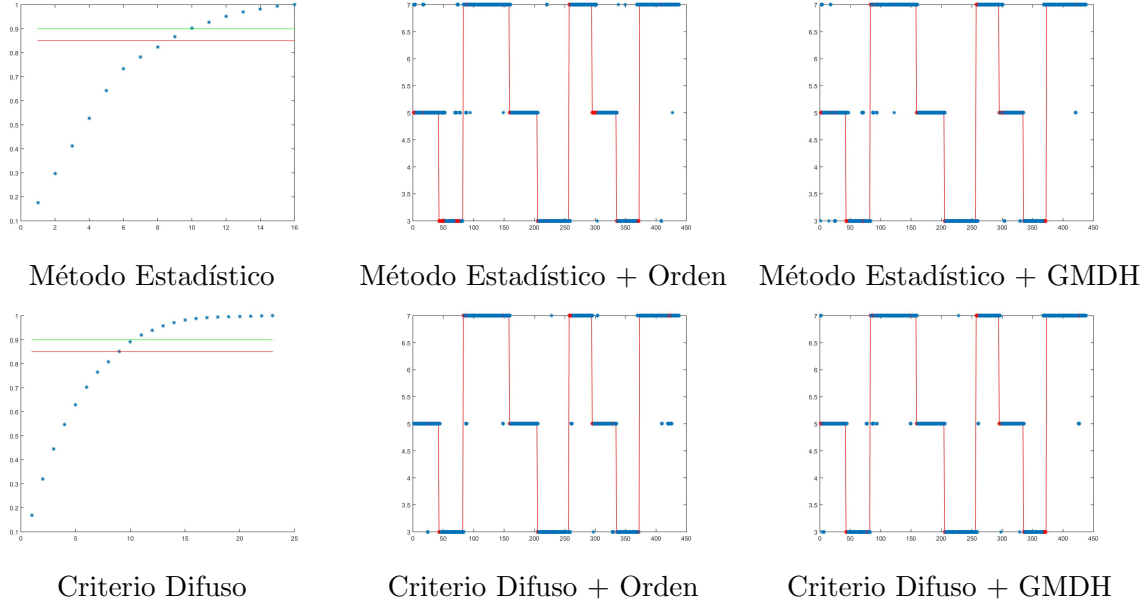


Figura J.1: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIComp. Sujeto 1

Tabla J.1: Matriz de confusión para los datos BCIComp Sujeto 1 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>85.39 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>87.67 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	96	22	12	Real Izquierda	113	12	5
Real Derecha	1	109	18	Real Derecha	9	105	14
Real Palabra	5	6	169	Real Palabra	6	8	166
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>89.95 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>89.5 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	120	6	4	Real Izquierda	113	10	7
Real Derecha	6	116	6	Real Derecha	5	116	7
Real Palabra	5	17	158	Real Palabra	4	13	163

## BCIComp Sujeto 2

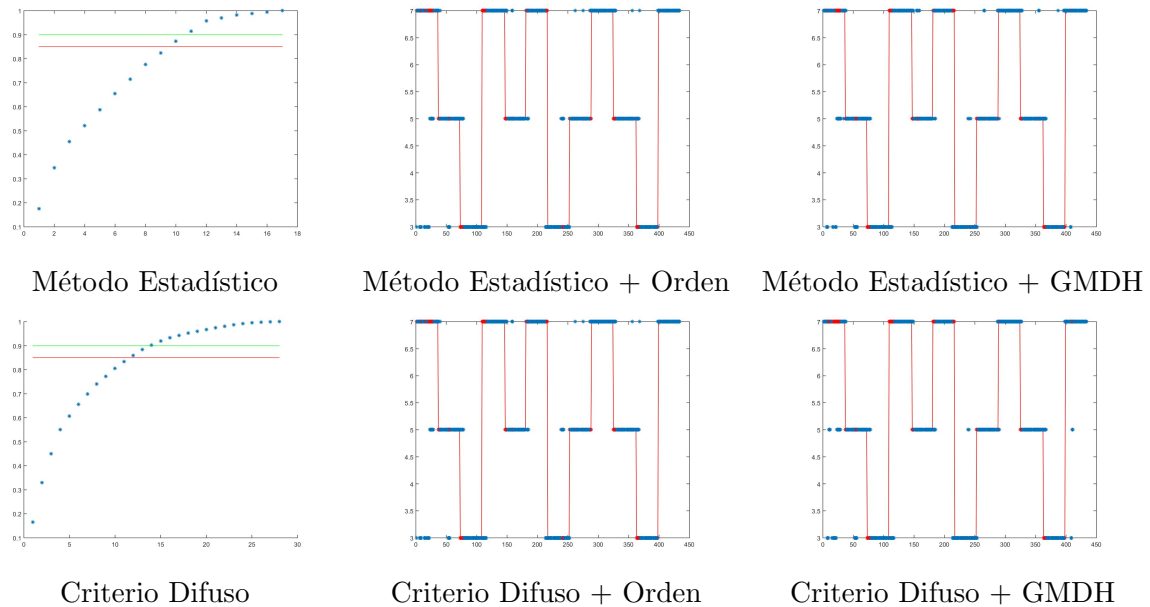


Figura J.2: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIComp. Sujeto 2

Tabla J.2: Matriz de confusión para los datos BCIComp Sujeto 2 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>81.80 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>81.57 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	90	16	2	Real Izquierda	90	14	4
Real Derecha	5	119	20	Real Derecha	8	116	20
Real Palabra	25	11	146	Real Palabra	21	13	148
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>81.80 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>82.49 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	90	16	2	Real Izquierda	94	13	1
Real Derecha	5	119	20	Real Derecha	7	127	10
Real Palabra	25	11	146	Real Palabra	26	19	137

## BCIComp Sujeto 3

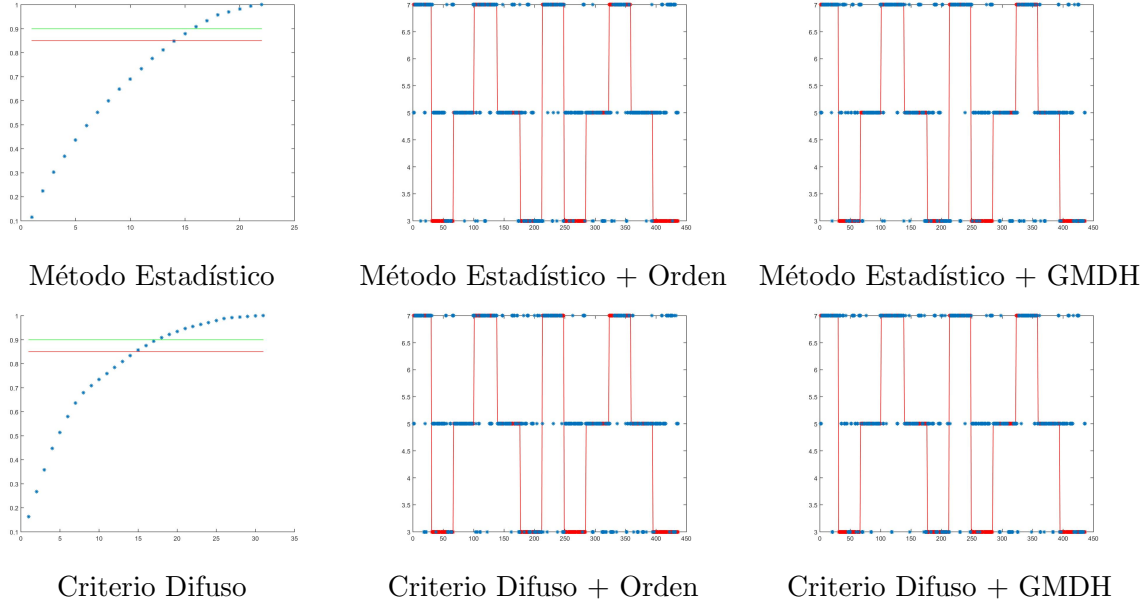


Figura J.3: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIComp. Sujeto 3

Tabla J.3: Matriz de confusión para los datos BCIComp Sujeto 3 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>57.57 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>59.40 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	36	83	31	Real Izquierda	44	70	36
Real Derecha	15	119	12	Real Derecha	23	108	15
Real Palabra	19	25	96	Real Palabra	17	16	107
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>52.52 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>57.80 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	29	89	32	Real Izquierda	38	75	37
Real Derecha	24	107	15	Real Derecha	28	101	17
Real Palabra	25	22	93	Real Palabra	12	15	113



## Apéndice K

# Resultados Selección de Características. Base de Datos BCIEpoc

Las siguientes tablas muestran los las tasas de acierto por valores de acierto por tarea y el comportamiento de éstos gráficamente. También se han incluido las matrices de confusión para un mejor entendimiento de los resultados presentados.

## BCIEpoc Sujeto 1

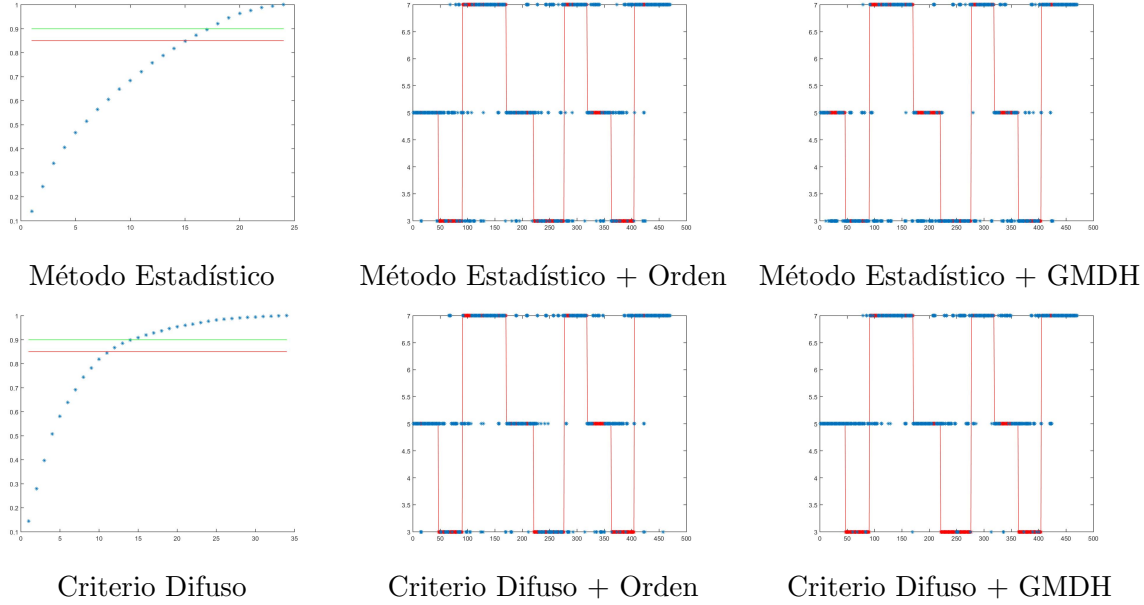


Figura K.1: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIEpoc. Sujeto 1

Tabla K.1: Matriz de confusión para los datos BCIEpoc Sujeto 1 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>59.79 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>63.62 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	40	60	42	Real Izquierda	101	19	22
Real Derecha	108	103	19	Real Derecha	66	62	12
Real Palabra	34	16	138	Real Palabra	42	10	136
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>64.47 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>59.79 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	51	58	33	Real Izquierda	13	90	39
Real Derecha	17	104	19	Real Derecha	2	114	24
Real Palabra	20	20	148	Real Palabra	2	32	154

## BCIEpoc Sujeto 2

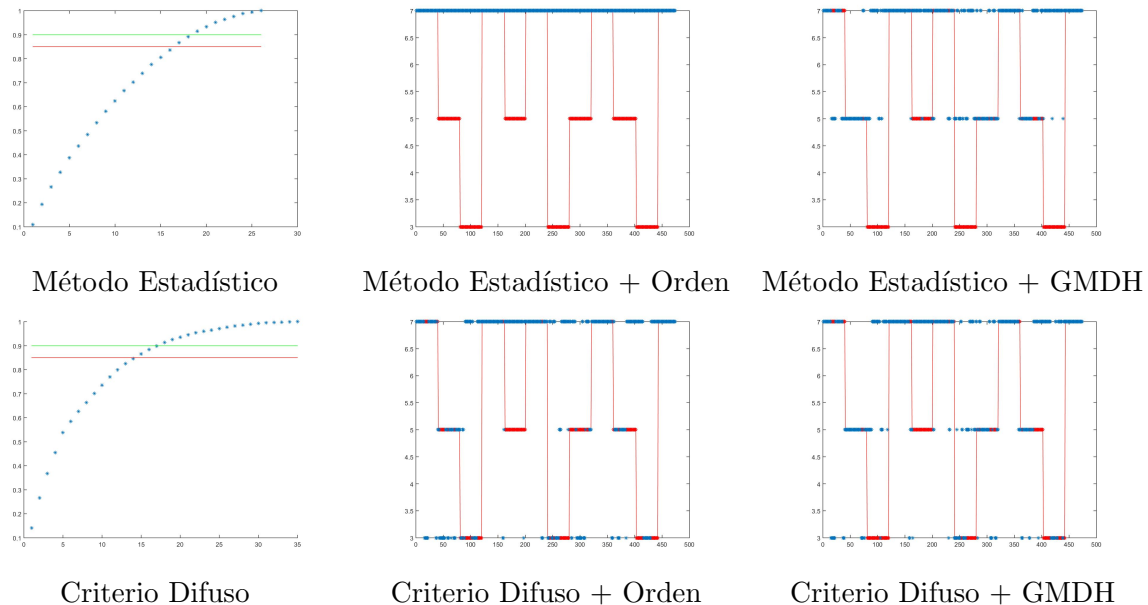


Figura K.2: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos BCIEpoc. Sujeto 2

Tabla K.2: Matriz de confusión para los datos BCIEpoc Sujeto 2 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>40.93 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>55.06 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	0	0	120	Real Izquierda	0	34	76
Real Derecha	0	0	160	Real Derecha	0	92	68
Real Palabra	0	0	194	Real Palabra	0	25	169
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>54.85 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>57.81 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	40	9	71	Real Izquierda	30	28	62
Real Derecha	41	45	74	Real Derecha	21	76	63
Real Palabra	17	2	175	Real Palabra	15	11	168

## BCIEpoc Sujeto 3

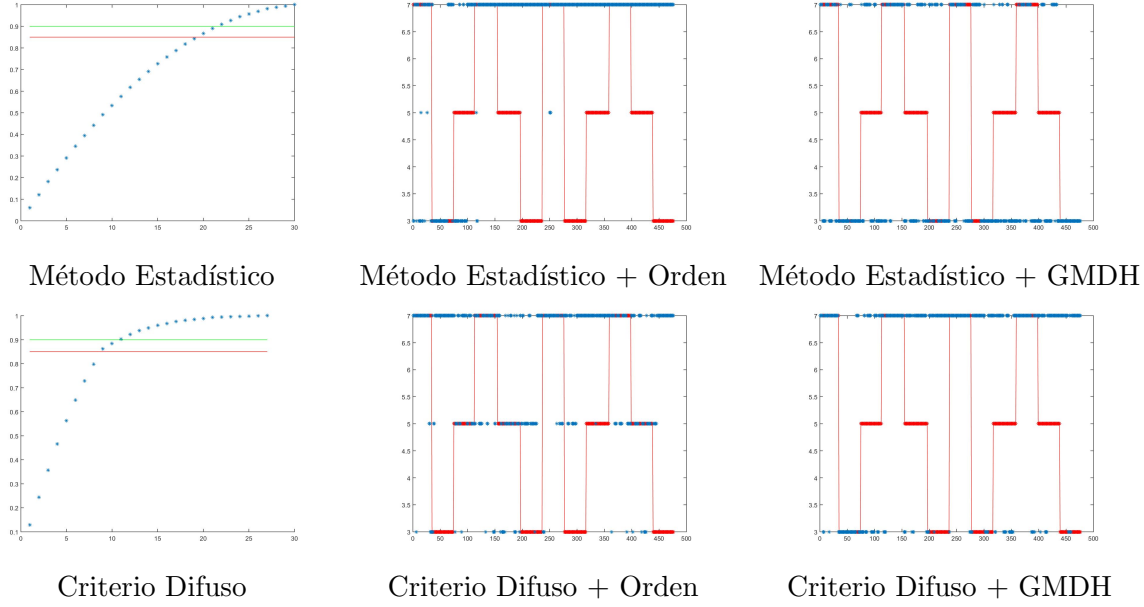


Figura K.3: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos BCIEpoc. Sujeto 3

Tabla K.3: Matriz de confusión para los datos BCIEpoc Sujeto 3 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>34.45 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>44.12 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	28	0	130	Real Izquierda	124	0	34
Real Derecha	20	0	142	Real Derecha	104	0	58
Real Palabra	14	6	136	Real Palabra	70	0	86
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>34.24 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>39.92 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	3	40	115	Real Izquierda	52	0	106
Real Derecha	18	53	91	Real Derecha	46	0	116
Real Palabra	13	36	107	Real Palabra	18	0	138

## Apéndice L

# Resultados Selección de Características. Base de Datos EmoEpoc

Las siguientes tablas muestran los las tasas de acierto por valores de acierto por tarea y el comportamiento de éstos gráficamente. También se han incluido las matrices de confusión para un mejor entendimiento de los resultados presentados.

## EmoEpoc Sujeto 1

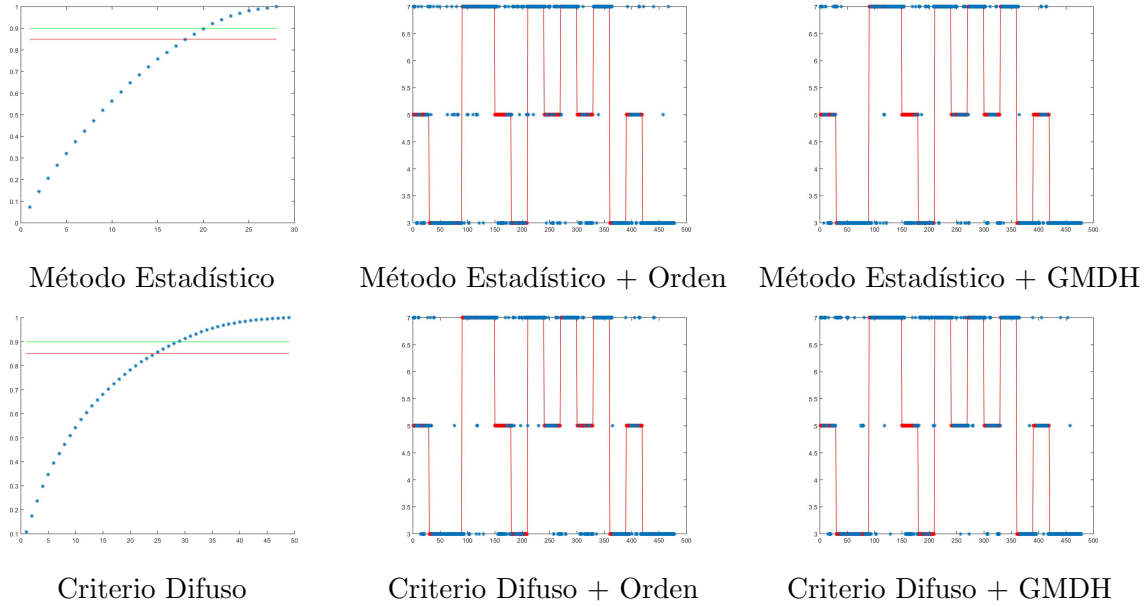


Figura L.1: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoEpoc. Sujeto 1

Tabla L.1: Matriz de confusión para los datos EmoEpoc Sujeto 1 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>63.39 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>67.78 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	135	13	31	Real Izquierda	157	3	19
Real Derecha	71	38	40	Real Derecha	66	40	43
Real Palabra	8	12	130	Real Palabra	19	4	127
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>66.11 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>67.78 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	143	11	25	Real Izquierda	122	12	45
Real Derecha	69	46	34	Real Derecha	44	68	37
Real Palabra	19	4	127	Real Palabra	8	8	134

## EmoEpoc Sujeto 2

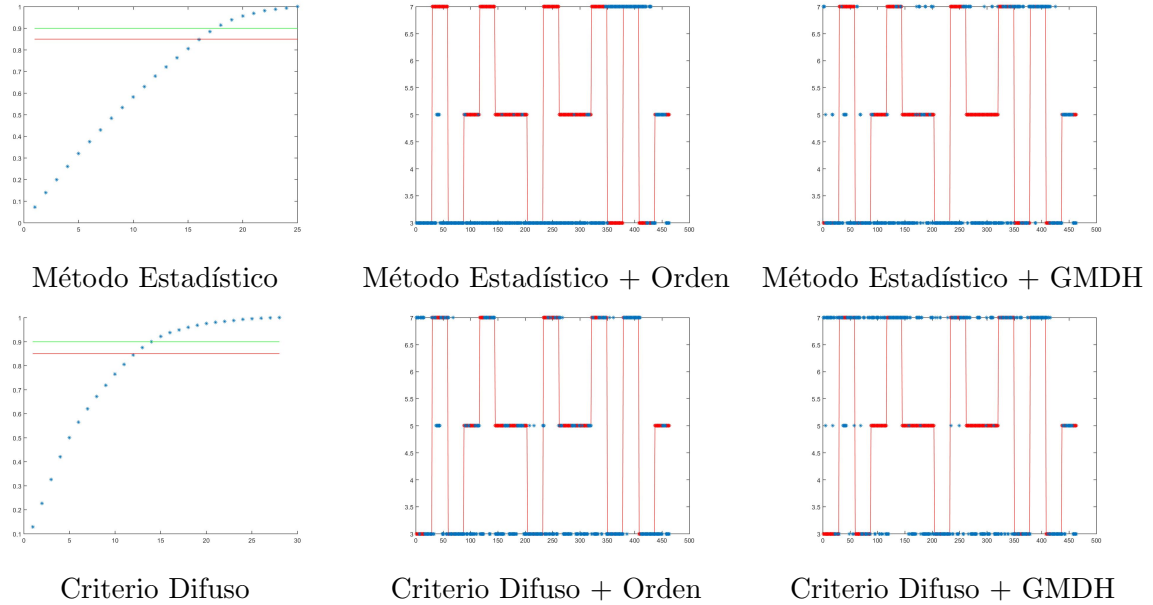


Figura L.2: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoEpoc. Sujeto 2

Tabla L.2: Matriz de confusión para los datos EmoEpoc Sujeto 2 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>34.56 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>41.25 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	98	0	47	Real Izquierda	108	5	32
Real Derecha	144	30	0	Real Derecha	122	32	20
Real Palabra	106	6	32	Real Palabra	85	8	51
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>54.21 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>44.06 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	120	3	22	Real Izquierda	82	3	60
Real Derecha	114	56	4	Real Derecha	89	19	66
Real Palabra	58	11	75	Real Palabra	31	10	103

## EmoEpoc Sujeto 3

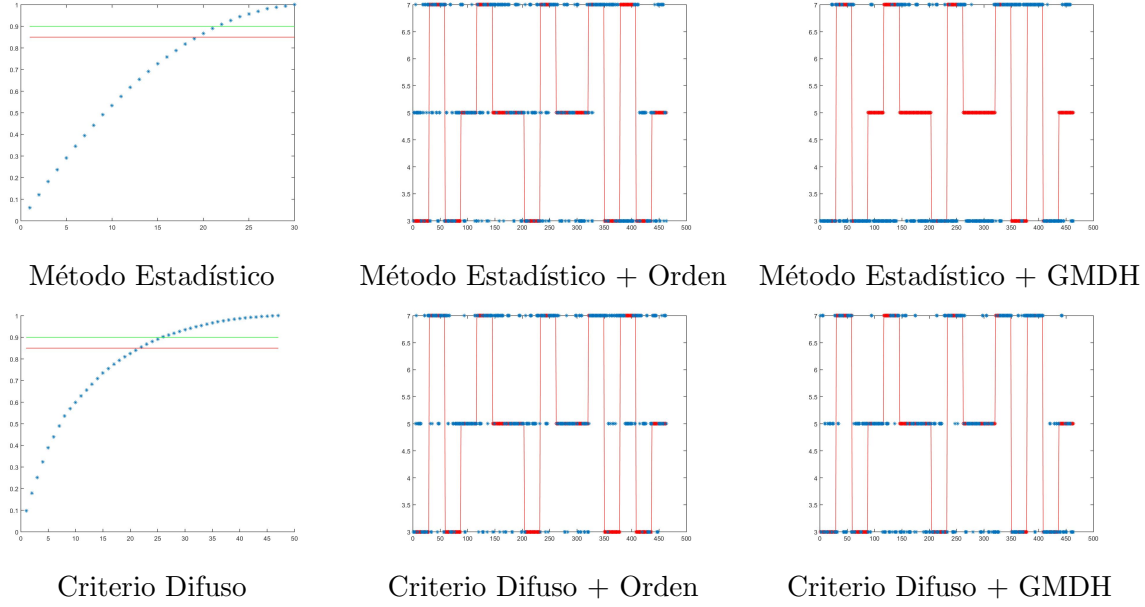


Figura L.3: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoEpoc. Sujeto 3

Tabla L.3: Matriz de confusión para los datos EmoEpoc Sujeto 3 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>38.23 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>39.09 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	43	54	48	Real Izquierda	100	0	45
Real Derecha	46	63	64	Real Derecha	122	0	51
Real Palabra	47	27	71	Real Palabra	64	0	81
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>48.16 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>55.72 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	29	58	58	Real Izquierda	70	50	25
Real Derecha	26	96	51	Real Derecha	61	92	20
Real Palabra	14	33	98	Real Palabra	39	10	96



## Apéndice M

# Resultados Selección de Características. Base de Datos EasyBCI

Las siguientes tablas muestran los las tasas de acierto por valores de acierto por tarea y el comportamiento de éstos gráficamente. También se han incluido las matrices de confusión para un mejor entendimiento de los resultados presentados.

## EasyBCI Sujeto 1

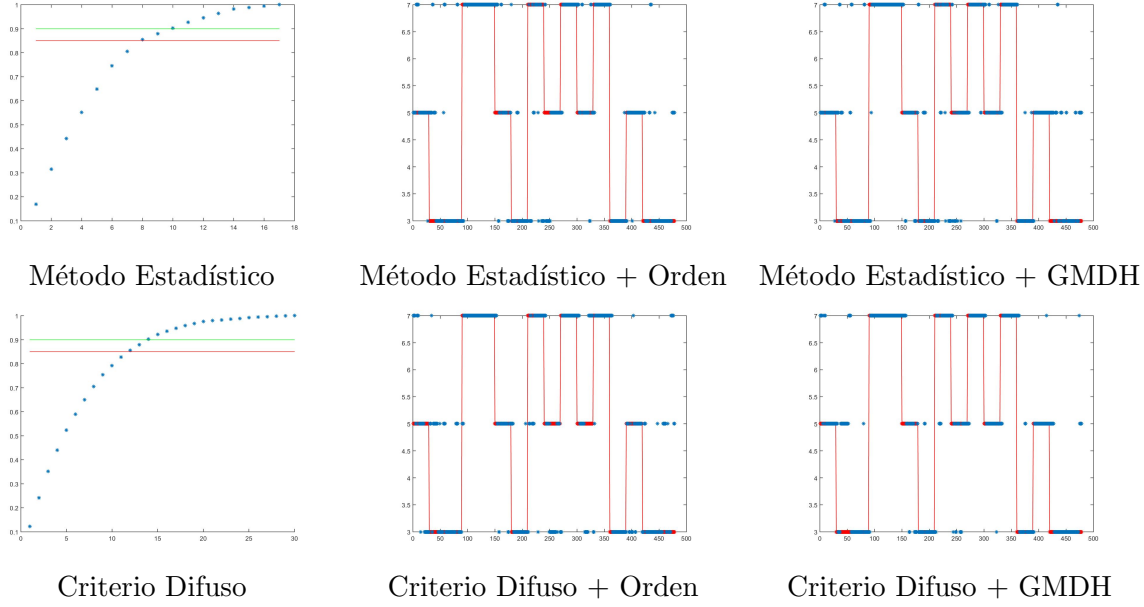


Figura M.1: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyBCI. Sujeto 1

Tabla M.1: Matriz de confusión para los datos EasyBCI Sujeto 1 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>76.15 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>74.88 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	138	28	13	Real Izquierda	124	42	13
Real Derecha	22	104	23	Real Derecha	20	113	16
Real Palabra	17	11	122	Real Palabra	16	15	119
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>69.25 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>78.45 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	129	39	11	Real Izquierda	134	35	10
Real Derecha	47	71	31	Real Derecha	17	108	24
Real Palabra	8	11	131	Real Palabra	5	12	133

## EasyBCI Sujeto 2

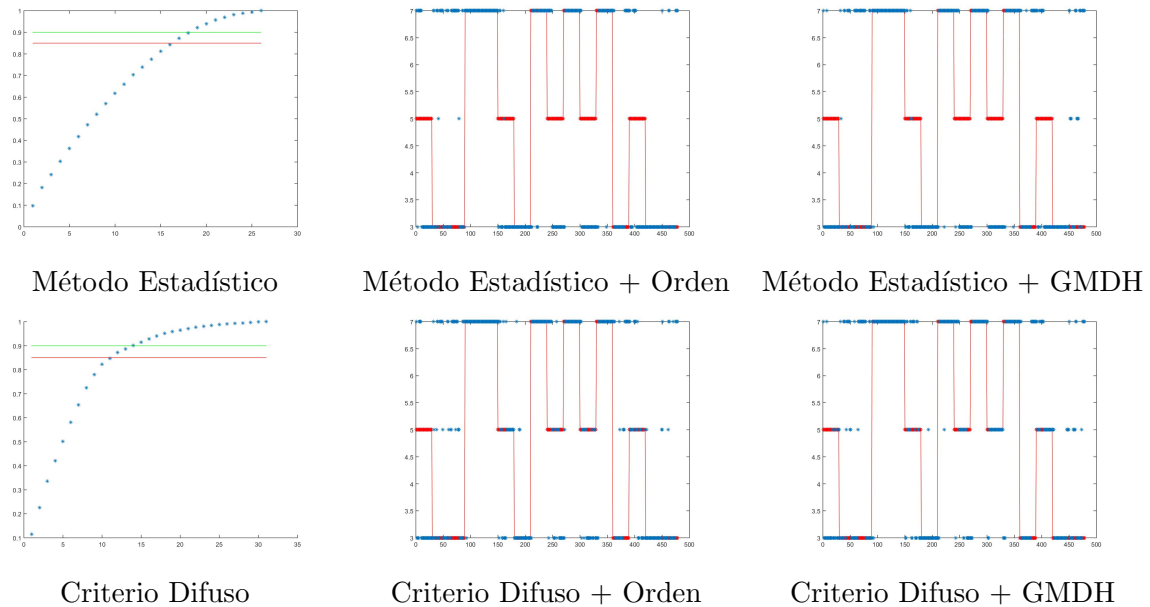


Figura M.2: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EasyBCI. Sujeto 2

Tabla M.2: Matriz de confusión para los datos EasyBCI Sujeto 2 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>55.44 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>53.77 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	128	2	49	Real Izquierda	117	8	54
Real Derecha	115	1	33	Real Derecha	120	2	27
Real Palabra	14	0	136	Real Palabra	12	0	138
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>63.18 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>67.36 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	113	20	46	Real Izquierda	115	18	46
Real Derecha	70	49	30	Real Derecha	46	71	32
Real Palabra	9	1	140	Real Palabra	13	1	136

## EasyBCI Sujeto 3

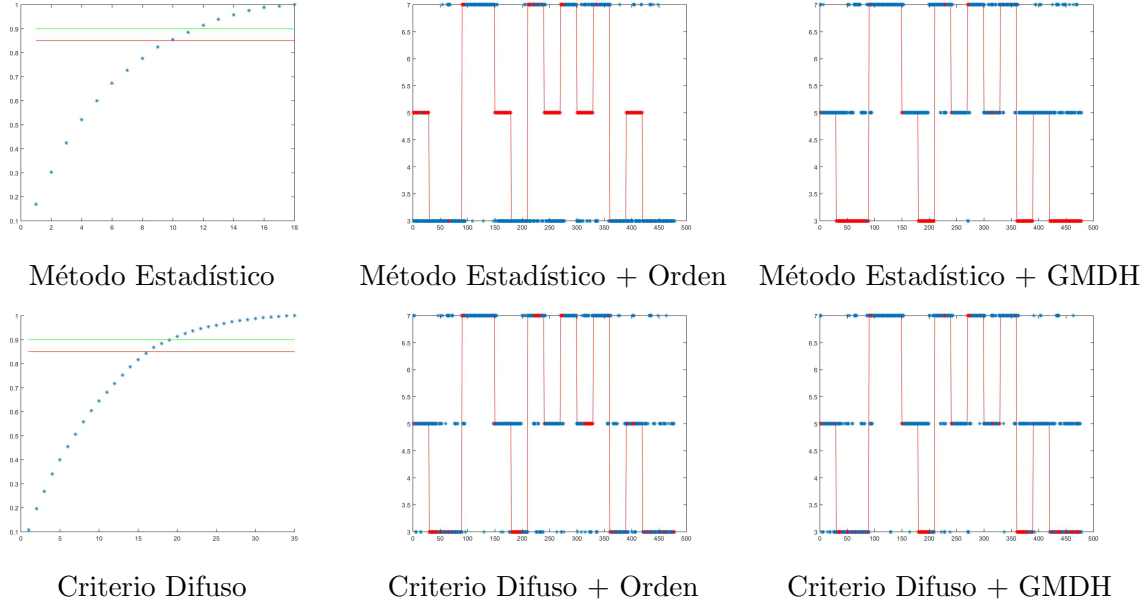


Figura M.3: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyBCI. Sujeto 3

Tabla M.3: Matriz de confusión para los datos EasyBCI Sujeto 3 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>55.86 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>51.05 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	162	0	17	Real Izquierda	1	128	50
Real Derecha	121	1	27	Real Derecha	0	119	30
Real Palabra	46	0	104	Real Palabra	2	24	124
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>56.90 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>57.11 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	68	81	30	Real Izquierda	46	106	27
Real Derecha	26	97	26	Real Derecha	12	111	26
Real Palabra	19	24	107	Real Palabra	11	23	116

## Apéndice N

# Resultados Selección de Características. Base de Datos EasyEpoc

Las siguientes tablas muestran los las tasas de acierto por valores de acierto por tarea y el comportamiento de éstos gráficamente. También se han incluido las matrices de confusión para un mejor entendimiento de los resultados presentados.

## EasyEpoc Sujeto 1

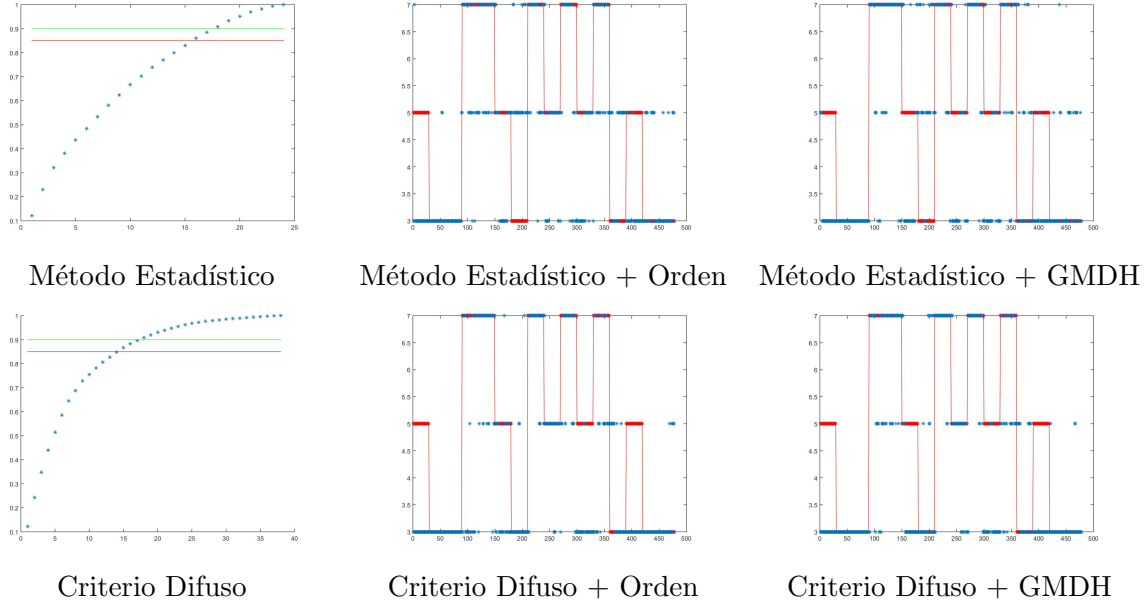


Figura N.1: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyEpoc. Sujeto 1

Tabla N.1: Matriz de confusión para los datos EasyEpoc Sujeto 1 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>52.03 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>52.72 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	112	61	6	Real Izquierda	121	40	18
Real Derecha	91	52	6	Real Derecha	112	25	12
Real Palabra	12	52	86	Real Palabra	18	26	106
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>58.37 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>58.58 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	159	19	1	Real Izquierda	155	18	6
Real Derecha	109	37	3	Real Derecha	116	27	6
Real Palabra	32	35	83	Real Palabra	16	36	98

## EasyEpoc Sujeto 2

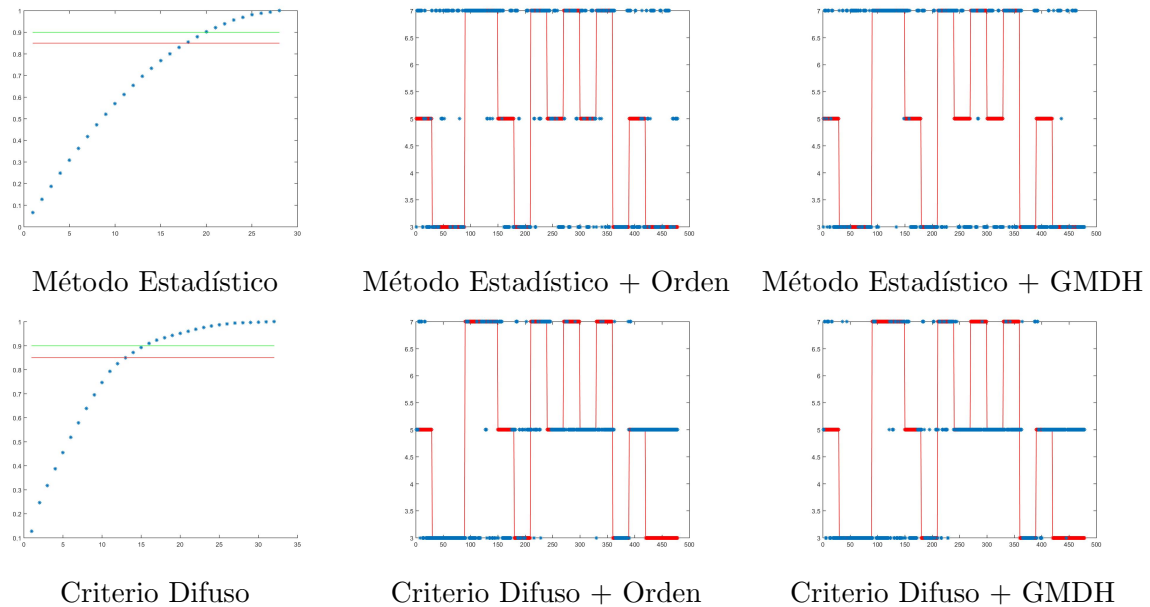


Figura N.2: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyEpoc. Sujeto 2

Tabla N.2: Matriz de confusión para los datos EasyEpoc Sujeto 2 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>47.07 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>48.12 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	88	20	71	Real Izquierda	112	1	66
Real Derecha	63	25	61	Real Derecha	89	6	54
Real Palabra	20	18	112	Real Palabra	35	3	112
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>47.49 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>46.03 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	93	80	6	Real Izquierda	98	70	11
Real Derecha	36	88	25	Real Derecha	40	88	21
Real Palabra	35	69	46	Real Palabra	46	70	34

## EasyEpoc Sujeto 3

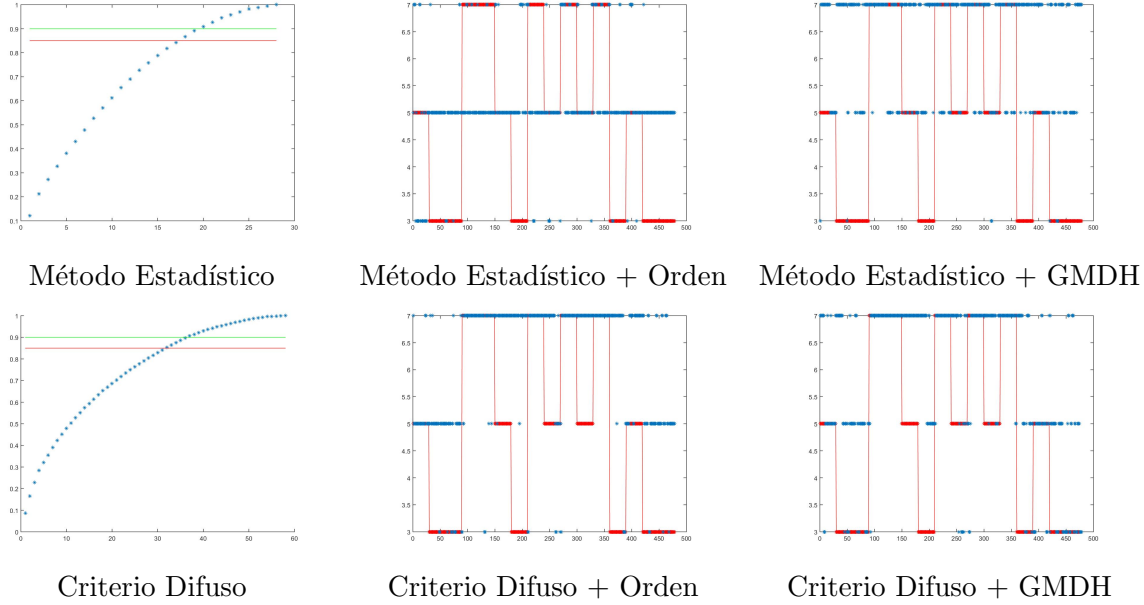


Figura N.3: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EasyEpoc. Sujeto 3

Tabla N.3: Matriz de confusión para los datos EasyEpoc Sujeto 3 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>30.13 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>33.47 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	6	158	15	Real Izquierda	5	54	120
Real Derecha	22	107	20	Real Derecha	3	47	99
Real Palabra	3	116	31	Real Palabra	0	42	108
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>41.42 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>47.28 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	18	92	69	Real Izquierda	44	80	55
Real Derecha	3	41	105	Real Derecha	15	45	89
Real Palabra	6	5	139	Real Palabra	3	10	137



## Apéndice Ñ

# Resultados Selección de Características. Base de Datos EmoExt

Las siguientes tablas muestran los las tasas de acierto por valores de acierto por tarea y el comportamiento de éstos gráficamente. También se han incluido las matrices de confusión para un mejor entendimiento de los resultados presentados.

## EmoExt Sujeto 1

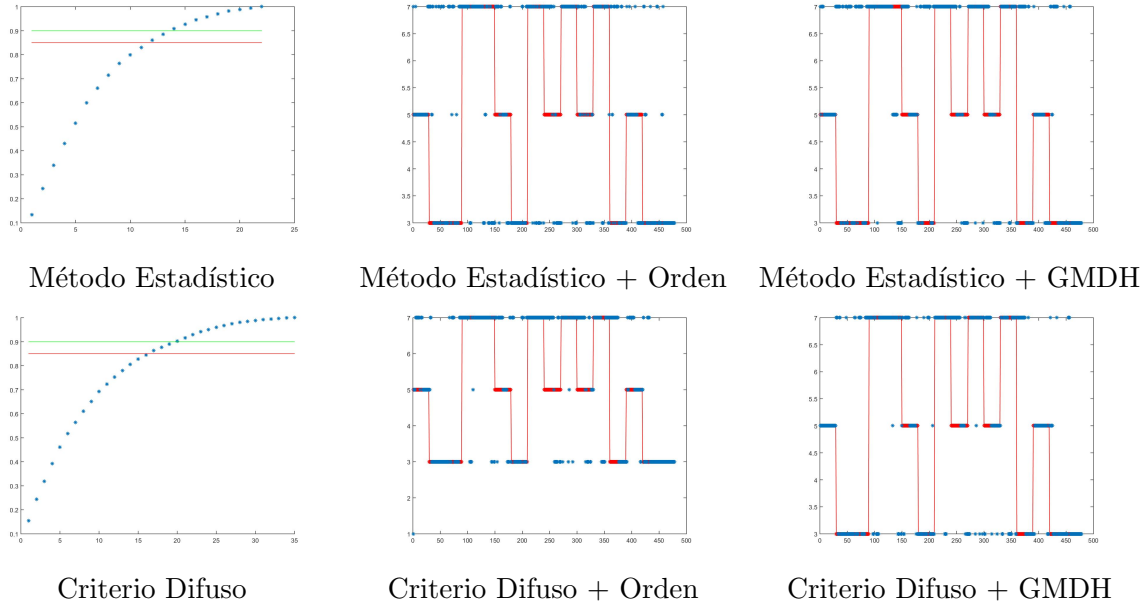


Figura Ñ.1: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 1

Tabla Ñ.1: Matriz de confusión para los datos EmoExt Sujeto 1 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>59.83 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>60.04 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	116	11	52	Real Izquierda	88	2	89
Real Derecha	39	61	50	Real Derecha	32	75	43
Real Palabra	37	3	109	Real Palabra	16	9	124
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>63.81 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>68.62 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	131	3	45	Real Izquierda	126	6	47
Real Derecha	26	46	77	Real Derecha	19	89	42
Real Palabra	18	3	128	Real Palabra	33	3	113

## EmoExt Sujeto 2

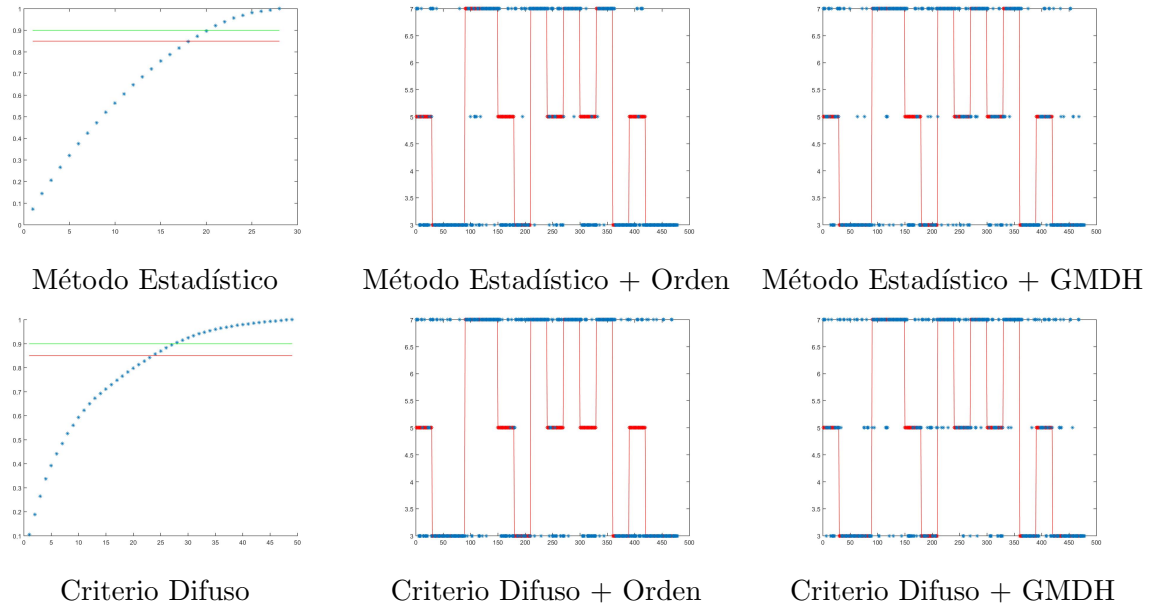


Figura N.2: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 2

Tabla N.2: Matriz de confusión para los datos EmoExt Sujeto 2 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>60.88 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>65.27 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	158	1	20	Real Izquierda	139	9	31
Real Derecha	96	14	39	Real Derecha	55	51	43
Real Palabra	22	9	119	Real Palabra	14	14	122
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>57.11 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>63.39 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	130	2	47	Real Izquierda	116	21	42
Real Derecha	91	10	48	Real Derecha	45	60	44
Real Palabra	17	0	133	Real Palabra	6	17	127

## EmoExt Sujeto 3

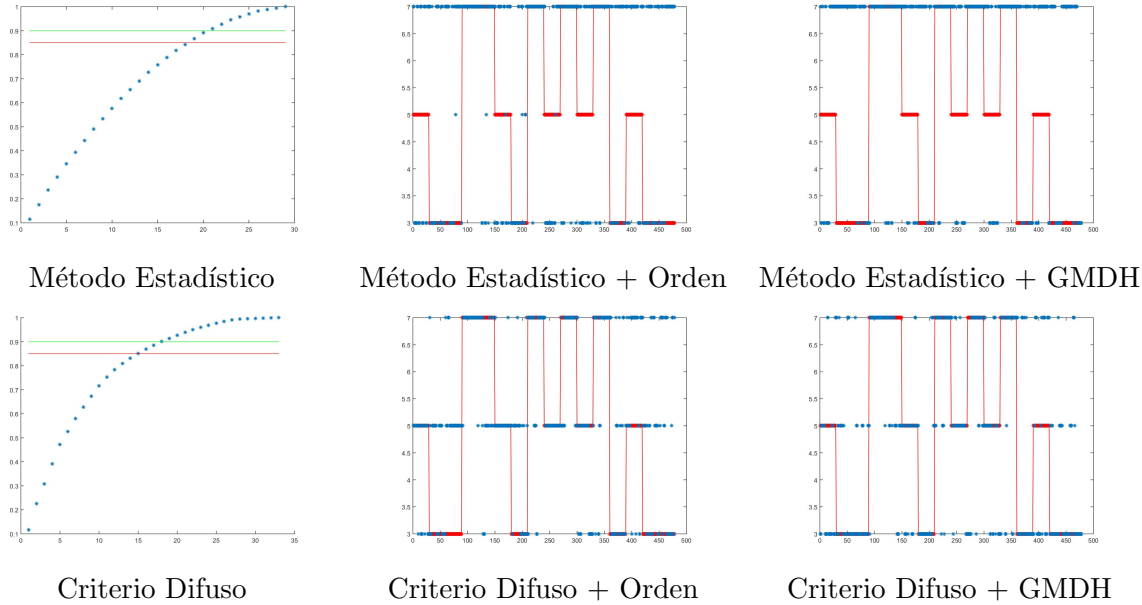


Figura Ñ.3: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 3

Tabla Ñ.3: Matriz de confusión para los datos EmoExt Sujeto 3 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>43.51 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>39.75 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	74	4	101	Real Izquierda	52	0	127
Real Derecha	62	2	85	Real Derecha	49	0	100
Real Palabra	17	1	132	Real Palabra	12	0	138
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>55.86 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>61.92 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	61	86	32	Real Izquierda	125	33	21
Real Derecha	24	101	24	Real Derecha	52	68	29
Real Palabra	10	35	105	Real Palabra	21	26	103

## EmoExt Sujeto 4

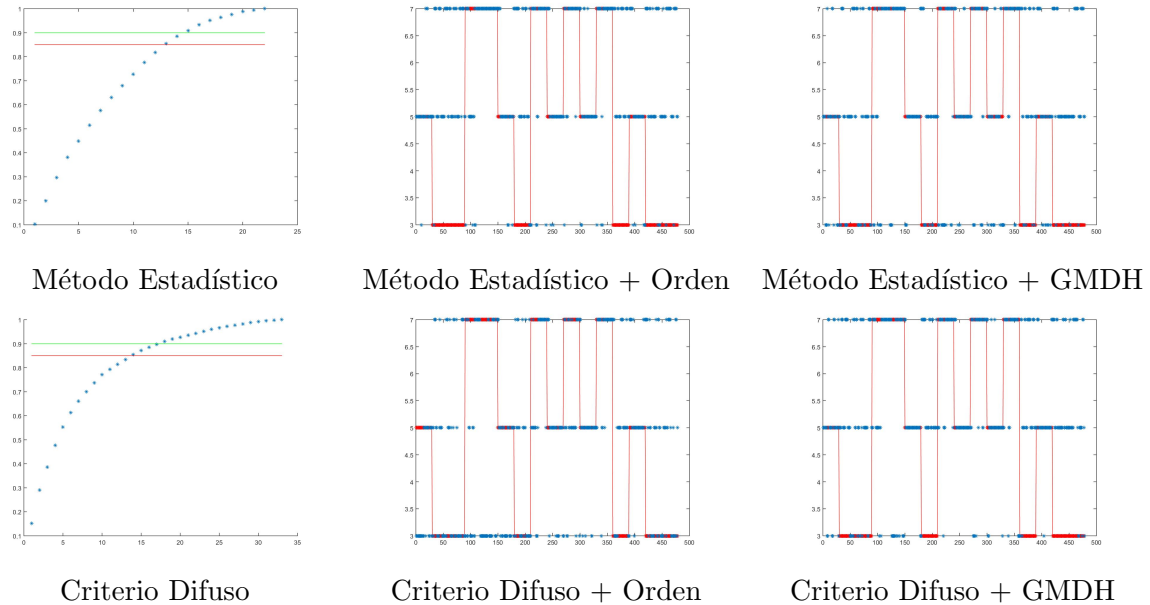


Figura Ñ.4: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 4

Tabla Ñ.4: Matriz de confusión para los datos EmoExt Sujeto 4 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>49.58 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>48.12 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	8	83	88	Real Izquierda	32	92	55
Real Derecha	13	11	25	Real Derecha	30	95	24
Real Palabra	13	19	118	Real Palabra	32	15	103
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>50.00 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>49.79 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	78	56	45	Real Izquierda	20	91	68
Real Derecha	45	88	16	Real Derecha	11	118	20
Real Palabra	44	33	73	Real Palabra	24	26	100

## EmoExt Sujeto 5

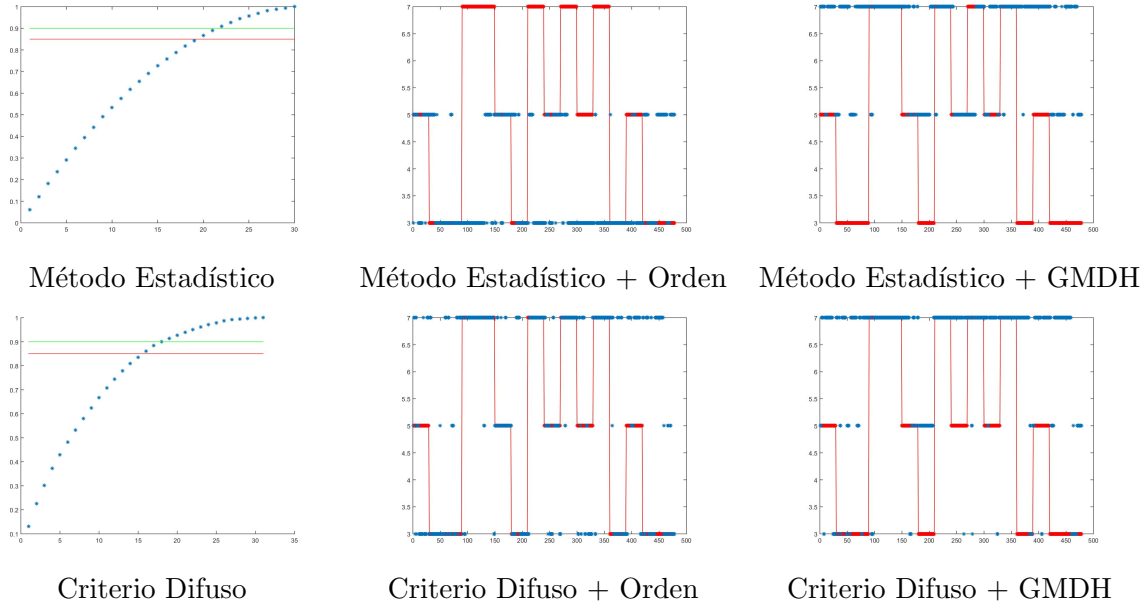


Figura Ñ.5: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 5

Tabla Ñ.5: Matriz de confusión para los datos EmoExt Sujeto 5 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>37.66 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>36.82 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	116	63	0	Real Izquierda	0	71	108
Real Derecha	85	64	0	Real Derecha	0	51	98
Real Palabra	116	34	0	Real Palabra	0	25	125
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>61.51 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>36.85 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	105	12	62	Real Izquierda	21	55	103
Real Derecha	47	55	47	Real Derecha	17	12	120
Real Palabra	12	4	134	Real Palabra	5	2	143

## EmoExt Sujeto 6

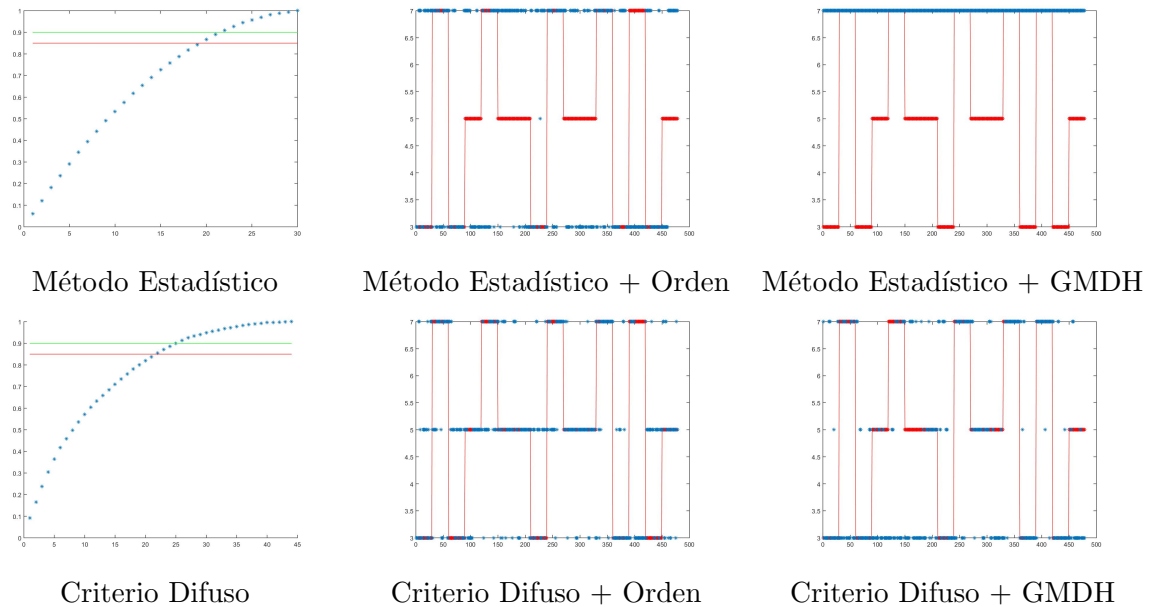


Figura Ñ.6: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 6

Tabla Ñ.6: Matriz de confusión para los datos EmoExt Sujeto 6 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>32.22 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>31.18 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	80	1	68	Real Izquierda	0	0	149
Real Derecha	77	0	102	Real Derecha	0	0	179
Real Palabra	76	0	74	Real Palabra	0	0	150
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>54.39 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>54.81 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	60	70	19	Real Izquierda	112	13	24
Real Derecha	33	125	21	Real Derecha	102	57	20
Real Palabra	36	39	75	Real Palabra	53	4	93

## EmoExt Sujeto 7

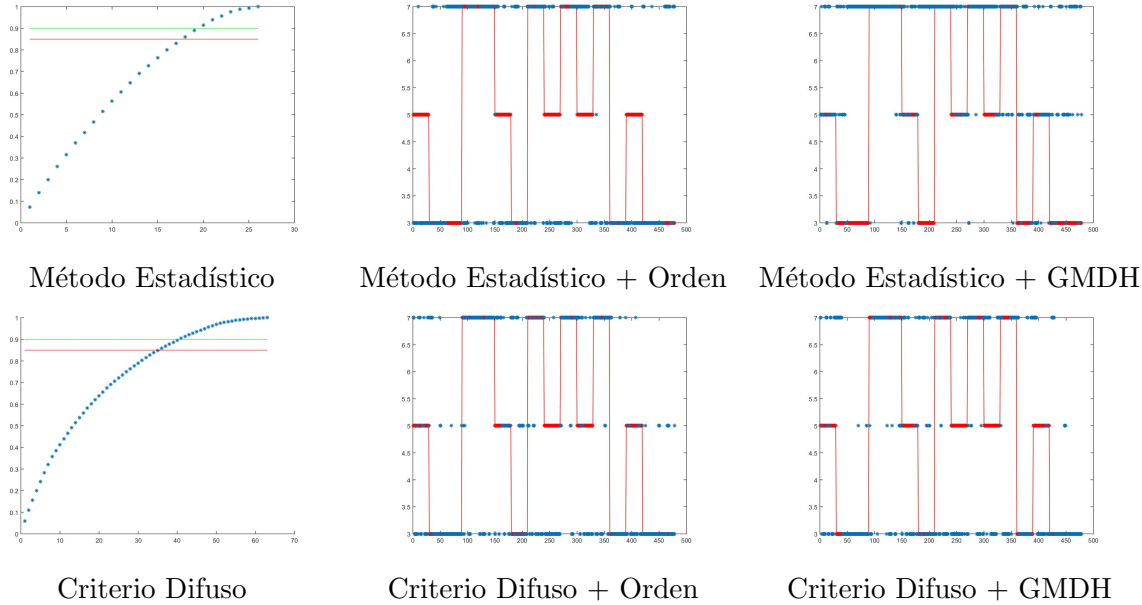


Figura Ñ.7: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 7

Tabla Ñ.7: Matriz de confusión para los datos EmoExt Sujeto 7 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>39.96 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>44.14 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	105	0	74	Real Izquierda	21	42	116
Real Derecha	102	1	45	Real Derecha	15	62	72
Real Palabra	64	1	85	Real Palabra	6	16	128
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>49.58 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>43.93 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	132	22	25	Real Izquierda	130	10	39
Real Derecha	95	22	32	Real Derecha	94	7	48
Real Palabra	53	14	83	Real Palabra	62	15	73



## EmoExt Sujeto 8

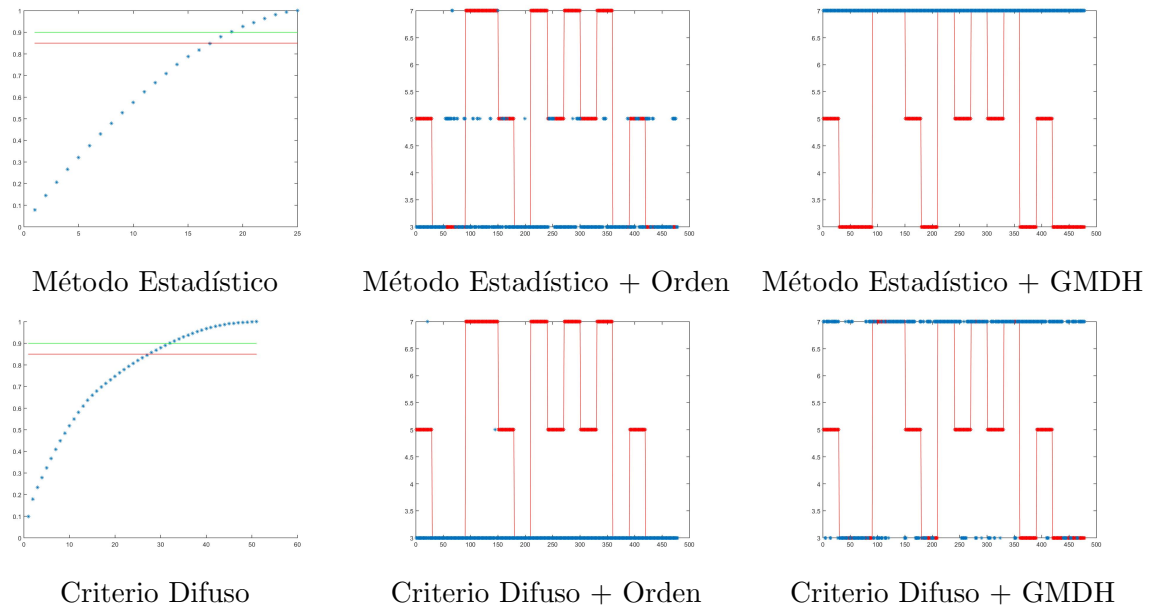


Figura Ñ.8: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 8

Tabla Ñ.8: Matriz de confusión para los datos EmoExt Sujeto 8 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>33.26 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>31.38 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	137	42	2	Real Izquierda	0	0	181
Real Derecha	126	21	0	Real Derecha	0	0	147
Real Palabra	129	20	1	Real Palabra	0	0	150
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>37.87 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>39.75 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	181	0	0	Real Izquierda	69	0	112
Real Derecha	146	0	1	Real Derecha	36	0	111
Real Palabra	149	1	0	Real Palabra	29	0	121

## EmoExt Sujeto 9

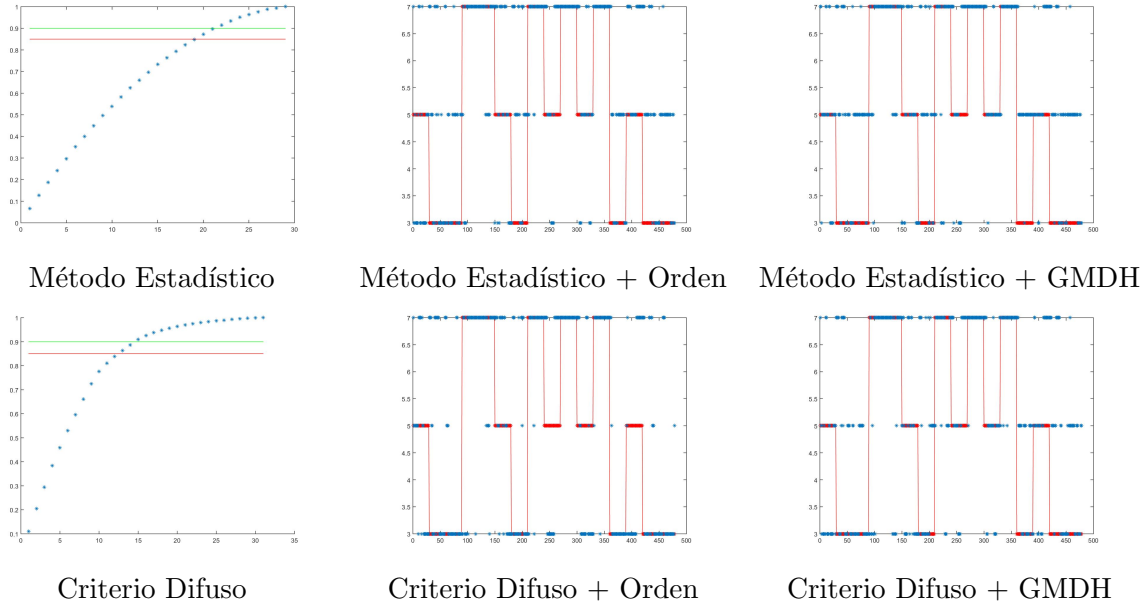


Figura Ñ.9: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 9

Tabla Ñ.9: Matriz de confusión para los datos EmoExt Sujeto 9 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>51.46 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>50.21 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	60	87	32	Real Izquierda	37	112	30
Real Derecha	37	53	59	Real Derecha	23	76	50
Real Palabra	4	13	133	Real Palabra	5	18	127
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>58.37 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>54.39 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	129	11	39	Real Izquierda	83	64	32
Real Derecha	71	21	57	Real Derecha	47	56	46
Real Palabra	15	6	129	Real Palabra	15	14	121

## EmoExt Sujeto 10

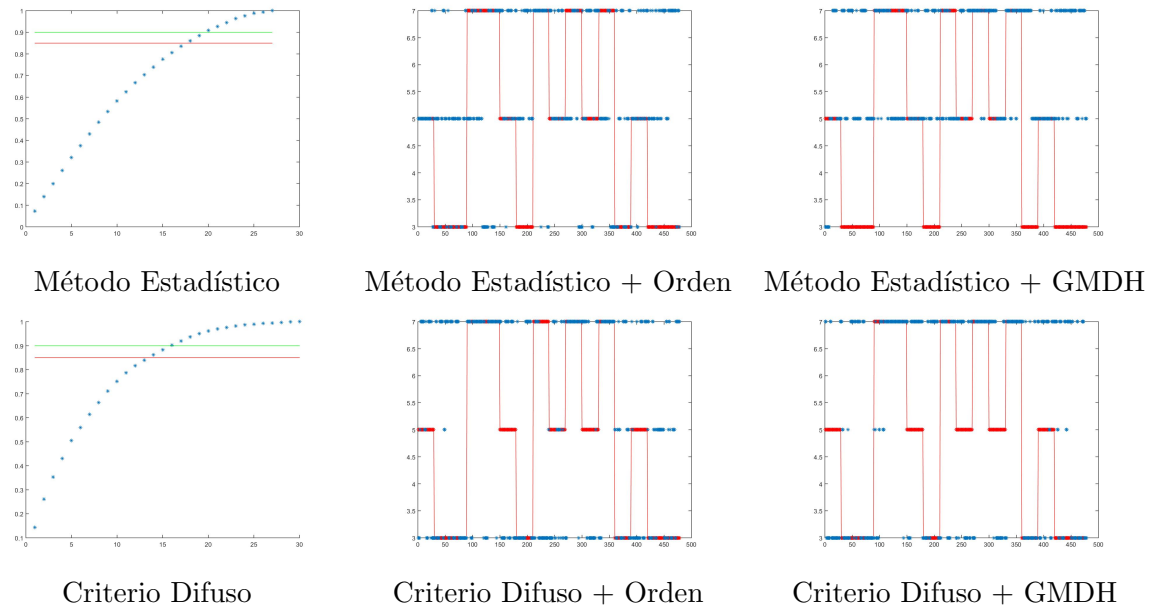


Figura N.10: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 10

Tabla N.10: Matriz de confusión para los datos EmoExt Sujeto 10 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>37.03 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>36.82 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	31	85	64	Real Izquierda	0	79	101
Real Derecha	10	83	57	Real Derecha	0	88	54
Real Palabra	35	50	63	Real Palabra	0	60	88
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>43.10 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>46.44 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	87	35	58	Real Izquierda	101	7	72
Real Derecha	73	13	64	Real Derecha	67	2	81
Real Palabra	41	1	106	Real Palabra	22	7	119

## EmoExt Sujeto 11

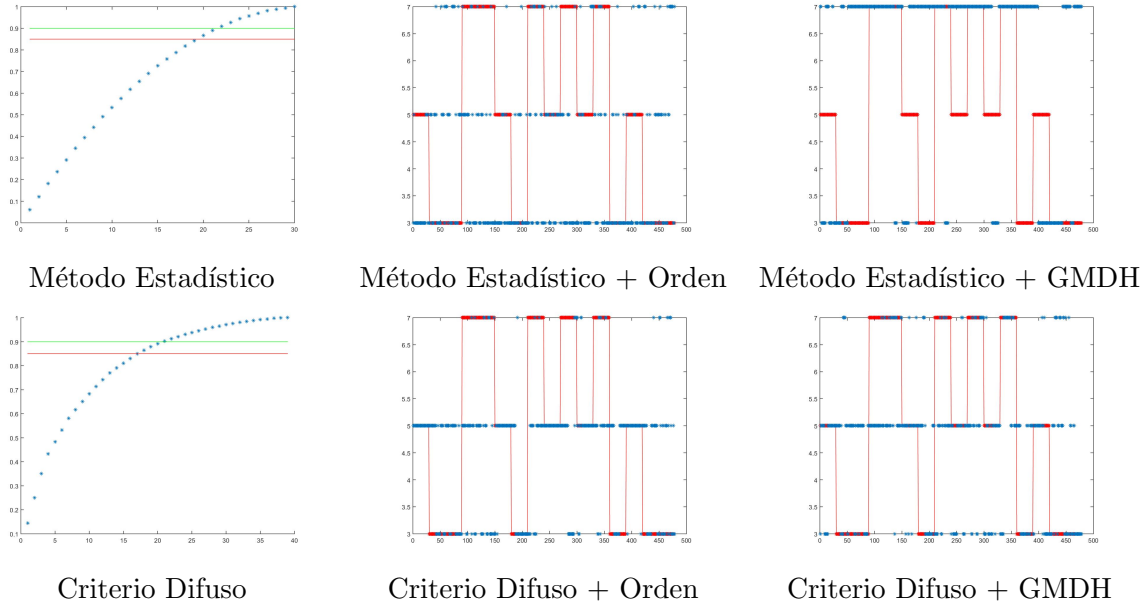


Figura Ñ.11: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda - *I*, 5 representa Derecha - *D* y 7 representa Palabra *P*. Datos EmoExt. Sujeto 11

Tabla Ñ.11: Matriz de confusión para los datos EmoExt Sujeto 11 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>33.47 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>38.70 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	102	49	28	Real Izquierda	45	0	134
Real Derecha	100	35	14	Real Derecha	64	0	85
Real Palabra	85	42	23	Real Palabra	10	0	140
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>49.79 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>46.03 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	80	91	8	Real Izquierda	78	83	18
Real Derecha	7	139	3	Real Derecha	45	97	7
Real Palabra	43	88	19	Real Palabra	19	86	45

## EmoExt Sujeto 12

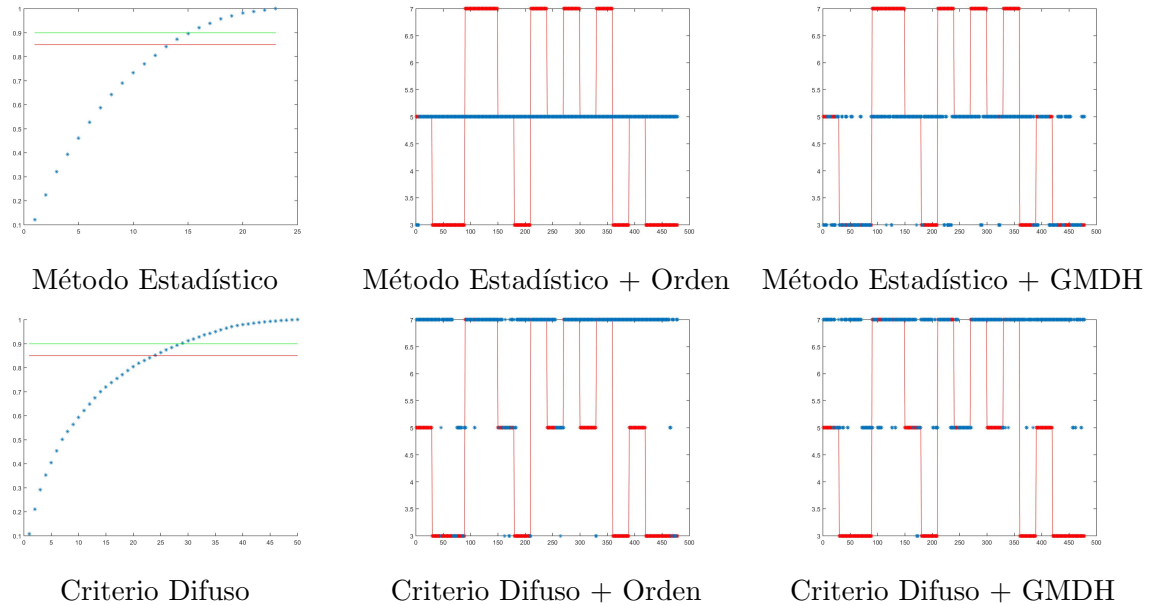


Figura N.12: Representación gráfica de los resultados de la clasificación después de aplicar los procesos de selección de características. Leyenda: 3 representa Izquierda -  $I$ , 5 representa Derecha -  $D$  y 7 representa Palabra  $P$ . Datos EmoExt. Sujeto 12

Tabla N.12: Matriz de confusión para los datos EmoExt Sujeto 12 para diferentes combinaciones de la metodología de selección de características

Método Estadístico + Orden				Método Estadístico + GMDH			
Acierto= <b>30.13 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>41.42 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	0	179	0	Real Izquierda	82	97	0
Real Derecha	5	144	0	Real Derecha	33	116	0
Real Palabra	0	150	0	Real Palabra	19	131	0
Criterio Difuso + Orden				Criterio Difuso + GMDH			
Acierto= <b>38.91 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra	Acierto= <b>33.68 %</b>	Predecir Izquierda	Predecir Derecha	Predecir Palabra
Real Izquierda	17	19	143	Real Izquierda	0	44	135
Real Derecha	5	26	118	Real Derecha	3	39	107
Real Palabra	2	5	143	Real Palabra	0	28	128



## Apéndice O

# Resultados Selección de Características. Modelo Común

Las siguientes tablas muestran las tasas de acierto generales para los modelos con características comunes a uno o varios sujetos para cada variante de la metodología de selección de características presentada en esta tesis doctoral.

Tabla O.1: Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Método Estadístico + Selección por Orden

	Método Estadístico + Orden			
	Todas	Comunes a 1	Comunes a 2	Comunes a 3
Sujeto 1	62.97	58.37	57.53	43.70
Sujeto 2	57.95	53.97	42.05	42.89
Sujeto 3	55.02	56.07	45.61	42.47
Sujeto 4	61.09	55.44	49.58	47.28
Sujeto 5	62.55	60.67	53.97	41.84
Sujeto 6	50.00	46.65	41.21	38.49
Sujeto 7	48.12	36.82	32.22	32.85
Sujeto 8	67.57	57.74	60.88	60.25
Sujeto 9	52.72	57.74	51.88	55.86
Sujeto 10	53.56	39.96	35.98	34.73
Sujeto 11	51.67	42.69	42.89	22.38
Sujeto 12	60.67	42.47	53.55	36.40
<b>Media</b>	56.99	50.72	47.28	41.60

Tabla O.2: Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Método Estadístico + Selección GMDH

Método Estadístico + GMDH				
	Todas	Comunes a 1	Comunes a 2	Comunes a 3
Sujeto 1	62.97	57.53	57.32	33.47
Sujeto 2	57.95	45.19	48.33	31.17
Sujeto 3	55.02	47.49	31.38	31.17
Sujeto 4	61.09	60.04	49.79	33.26
Sujeto 5	62.55	55.02	47.49	31.38
Sujeto 6	50.00	34.96	37.45	31.17
Sujeto 7	48.12	34.52	37.87	30.96
Sujeto 8	67.57	69.77	64.44	51.46
Sujeto 9	52.72	50	50.21	33.05
Sujeto 10	53.56	41.42	40.17	37.87
Sujeto 11	51.67	41.63	39.33	37.66
Sujeto 12	60.67	40.59	42.26	38.49
<b>Media</b>	56.99	48.18	45.50	35.09

Tabla O.3: Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Criterio Difuso + Selección por Orden

Criterio Difuso + Selección por Orden												
	Todas	Com 1	Com 2	Com 3	Com 4	Com 5	Com 6	Com 7	Com 8	Com 9	Com 10	Com 11
Sujeto 1	62.97	57.32	70.08	69.67	65.06	60.88	66.95	57.95	60.25	58.79	38.91	39.54
Sujeto 2	57.95	48.12	59.41	51.88	47.70	40.59	50.00	44.14	41.00	36.19	35.98	31.17
Sujeto 3	55.02	44.14	50.63	41.42	43.72	44.35	39.12	36.19	34.31	39.75	38.49	37.87
Sujeto 4	61.09	53.97	55.02	48.54	45.61	56.69	45.61	49.79	48.95	44.14	49.37	46.86
Sujeto 5	62.55	58.58	54.81	58.16	51.26	50.84	48.54	51.88	43.93	42.47	51.46	47.49
Sujeto 6	50.00	48.74	49.16	45.82	46.44	41.84	46.03	50.84	41.21	36.19	39.96	38.70
Sujeto 7	48.12	45.61	37.24	37.66	37.66	32.85	36.82	38.08	35.98	35.36	32.26	37.66
Sujeto 8	67.57	60.88	65.48	60.46	63.60	53.35	51.67	45.82	51.67	59.21	50.00	44.35
Sujeto 9	52.72	55.65	56.28	52.51	54.39	55.44	53.56	55.23	53.77	52.51	53.14	55.44
Sujeto 10	53.56	48.74	46.86	32.85	39.54	40.59	39.75	33.47	40.79	42.89	37.87	37.87
Sujeto 11	51.67	42.89	42.47	43.31	43.93	43.72	42.47	45.82	38.49	35.36	36.61	38.28
Sujeto 12	60.67	53.14	56.07	42.26	51.67	55.23	58.79	47.91	39.75	47.91	31.38	41.63
<b>Media</b>	51.69	51.48	53.63	48.71	49.22	48.03	48.28	46.43	44.18	44.23	41.29	41.41



Tabla O.4: Niveles de acierto alcanzados seleccionando conjuntos comunes de características a varios usuarios en %. Base de datos EmoExt. Combinación Criterio Difuso + Selección GMDH

<b>Criterio Difuso + Selección GMDH</b>				
	<b>Todas</b>	<b>Comunes a 1</b>	<b>Comunes a 2</b>	<b>Comunes a 3</b>
Sujeto 1	62.97	63.60	59.00	56.69
Sujeto 2	57.95	45.61	37.45	31.59
Sujeto 3	55.02	42.26	35.98	39.33
Sujeto 4	61.09	50.42	42.89	50.84
Sujeto 5	62.55	64.02	44.56	31.38
Sujeto 6	50.00	44.56	40.59	44.56
Sujeto 7	48.12	42.05	34.10	33.05
Sujeto 8	67.57	64.85	53.77	31.17
Sujeto 9	52.72	53.14	51.46	31.80
Sujeto 10	53.56	41.63	34.1	37.87
Sujeto 11	51.67	43.51	29.71	30.33
Sujeto 12	60.67	48.54	47.7	35.98
<b>Media</b>	56.99	50.35	42.61	37.88



# Publicaciones

El desarrollo de la presente tesis doctoral ha supuesto la publicación de los siguientes trabajos:

1. Juan Antonio Martínez, José Manuel Cano and Julio Ibarrola, “Towards a reliable BCI system with a low cost headset” in ‘*Proceedings of the 4th EMUNI Research Resouk*, 2012.
2. Juan-Antonio Martinez-Leon, Jose-Manuel Cano-Izquierdo and Julio Ibarrola. “Feature Selection Applying Statistical and Neurofuzzy Methods to EEG-Based BCI,” *Computational intelligence and neuroscience*, vol. 2015, p.54, 2015. [161]
3. Juan-Antonio Martinez-Leon, Jose-Manuel Cano-Izquierdo and Julio Ibarrola. “Are low cost brain computer interface headsets ready for motor imagery applications?,” *Expert Systems with Applications*, vol 49, pp. 136-144, 2016. [160]

## **Towards a reliable BCI system with a low cost headset**

**Juan Antonio Martínez, José Manuel Cano and Julio Ibarrola, Universidad Politécnica  
de Cartagena, Spain**

[Juan.MartinezLeon@gmail.com](mailto:Juan.MartinezLeon@gmail.com), [JoseM.Cano@upct.es](mailto:JoseM.Cano@upct.es), [JulioJose.Ibarrola@upct.es](mailto:JulioJose.Ibarrola@upct.es)

### **Abstract**

This paper presents a research to develop a BCI control system based on EEG by using a low cost signal Emotiv EPOC acquisition headset. The stages of signal acquisition, pre-processing and classification are analyzed in comparison with previous encouraging results achieved by the authors employing the BCI Competition III set V data. The main previous contributions have been founded on the application of a Neuro-Fuzzy S-dFasArt processing method, where the success rate achieved at the classification stage has clearly overcome the results of the BCI Competition winner. The objective is to reduce the number of characteristics taken into account to complete the classification task while maintaining and even improving the success rate of the scheme for the whole montage. This methodology decreases the computational burden allowing an on-line processing and classification when applying EEGs in real time systems.

Keyword: EEG signals, classification, BCI

## 1 INTRODUCTION

Brain-computer interfaces (BCI) systems capture brain signals and decode them into control signals, which allow interfacing with certain devices without any muscular intervention. For this reason, these sorts of techniques are particularly useful for people with severe communication impairments.

Brain signals can be registered using invasive and non-invasive systems. Invasive technologies use microelectrodes implanted into the brain whereas non-invasive technologies, based on electroencephalogram (EEG) techniques, place the electrodes on the scalp. Invasive technologies have demonstrated to benefit from a better signal to noise ratio and transfer rate (Lebedev and Nicolelis 2006, 538), but they create both medical and ethical concerns when they are used in humans. This causes the most extended choices to be based on non-invasive approaches, focusing in the use of EEG (J. del R. Millán et al 2009, 3361).

Any BCI control system based on EEGs can be divided in four high-level stages: data acquisition, pre-processing, classification and control signal generation. Data acquisition and pre-processing get the signal from the individual, apply filters to increase the signal-to-noise ratio and alter the nature of the data for feature extraction. At the third stage, the categorization into a mental task takes place by using a classification algorithm. Then, a signal to act on a device will be generated. In our research we have concentrated on the first three stages, performing off-line analysis of different sets of data.

The EEG technology is the part of the BCI control system used to gather the data and it is represented by multiple headset models within the market. These headsets are mainly differentiated by the number, technology, typology (dry or wet) and the layout of the sensors on the scalp. Other parameters affecting this classification are the hardware associated with the signal acquisition or the communication channel with the receiver. Obviously combinations of these features lead to a large range of devices with a wide range of cost.

Our investigation ambition is to successfully perform on-line detection of mental states from spontaneous EEG signals by using a low cost device. The conditions to differentiate have been defined as user imagining left hand movement, right hand movement and generation of words beginning with the same random letter switched randomly at an operator's request every 15 seconds. The headset used on this study is the Emotiv EPOC.

In order to determine the quality of the Emotiv EPOC results, these are being compared with the sample files of the Set V dataset available for the BCI competition III (Berlin Brain-Computer Interface 2004), which is used as a baseline.

Figure 1: Emotiv Epoc headset



Source: (Emotiv 2012).

## 2 METHODOLOGY

### 2.1 Data Description

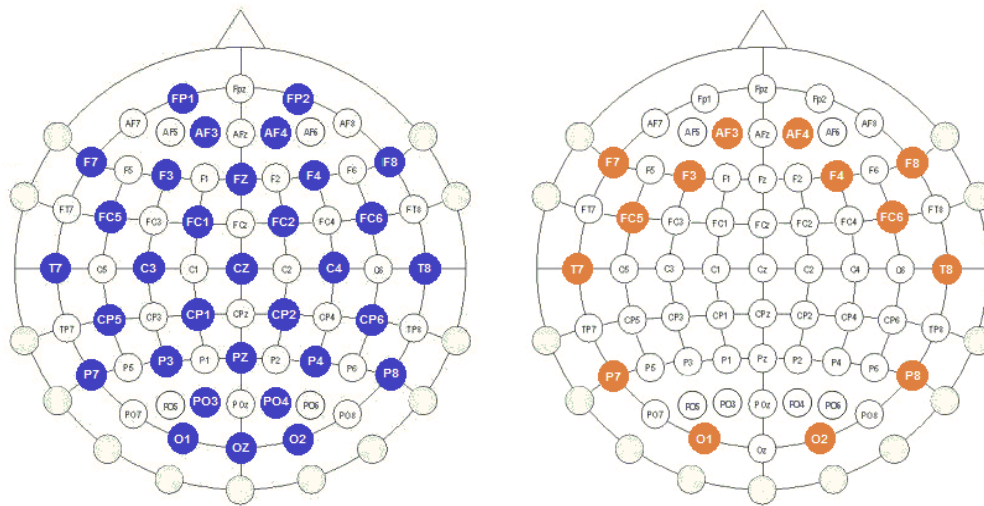
Two different sets of data are being used in this research. The first one was provided by the IDIAP Research Institute of Switzerland for the BCI Competition III, organized in 2004 by the Berlin Brain-Computer Interface area of Berlin Institute of Technology. This set was recorded by a Biosemi system using a cap with 32 integrated electrodes located at standard positions of the International 10-20 system. The sampling rate was 512 Hz. Signals were acquired at full DC. No artifact rejection or correction was employed.

The dataset contains data from 3 normal subjects, who recorded 4 sessions imagining left hand movement, right hand movement and generation of words beginning with the same random letter switched randomly at the request of an operator every 15 seconds. All sessions were obtained during the same day, each lasting 4 minutes with 5-10 minutes breaks between them. The forth recording of each user was provided as a test session and the results of the classification are not available.

The second source of data has been an Emotiv EPOC, which only provides 14 electrodes and a sampling frequency of 128 Hz to the end user. No artifact rejection or correction has been employed. This dataset is based on only 1 person contribution replicating the BCI Competition III Set V experiment as per above.

The EEG activity recorded on these files is used as a baseline for subsequent analysis of the mental tasks.

Figure 2 - Sensor distribution of the Biosemi (left) and the Emotiv EPOC (right) headsets



Source: Prepared by the authors.

As can be seen, the Emotiv EPOC sensor positions are all included on the Biosemi headset, but it lacks of any sensor on the motor cortex area of the brain, where the motor decisions are made (E. Iáñez, 2009), representing a mayor challenge for this research.

## 2.2 Pre-processing

The EEG potentials measured on the scalp have very low amplitude. For this reason, any interference coming from sources such as eye movement, eye-blink, any muscular movement, teeth clash or the heart rhythm deeply affect the quality of the signal measured. This can prevent the decoding system to recognize the control signal recorded properly.

The purpose of the pre-processing stage is to increase the signal-to-noise ratio of the recorded control EEG signal. Two different spatial filtering methods have been applied in our research to address this issue: Common Average Reference (CAR) and a Surface Laplacian (SL) computation (McFarland et al 1997, 387). Both methods work as a high-pass spatial filter, returning almost reference-free signals.

In the CAR method, the average value of the potentials in all the electrodes at a certain time is subtracted from that of the channel of interest. This processing affects the signal by reducing the impact of signals present in a large proportion of the electrodes of the montage.

The Laplacian Surface method emphasizes the activity of the signals surrounding the channel of interest. The value of the SL at each electrode location is calculated as an estimation of the radial current density at that location. This method includes the calculation of the second

order spatial derivatives of the instantaneous spatial voltage distribution. However, for our study, the calculation will be based on a finite difference method which approximates the second derivative by subtracting a weighted mean of the surrounding potentials of the channel of interest.

In both methods the number of electrodes is a relevant parameter in the calculations. CAR method is based on the assumption of uniform and complete electrode coverage of the scalp as well as the Surface Laplacian, which has also demonstrated to increase the spatial resolution of the EEG in function of the number of sensors of the montage (Babiloni et al 2001, 323).

The data obtained from these methods have been computed by estimating the Power Spectral Density (PSD) for the frequency band between 8 and 30 Hz with a resolution of 2 Hz. The records have been divided in windows of 1s with an advance rate based on the sampling frequency divided by 16, which defines an overlapping of 93.75% between windows. These have been individually processed by dividing the window in 8 segments with 50% overlapping, with a Hanning window of the same length applied to each segment. The PSD calculation is based on the Welch periodogram algorithm.

### **2.3 Classification**

The classification stage of the process interprets the potentials captured on the scalp and decodes it into one of the valid statuses associated to the control signal. The pre processed channel information captured by the montage is processed again to obtain meaningful information from the user.

Depending on the application, the outcome of this stage can be used to act on software applications installed on mobile phones (Wang 2011, 2), video games (Emotiv 2012), wheel chairs or even cars (Autonomos Labs 2011).

For this paper, an implementation of the Fisher Linear Discriminant has been used to compare the quality of the classification process of the different sets. The success rate of the classification stage is detailed on the table below.



Table 1: Success rate on the different training sets for both the Emotiv and the Biosemi headsets

Training Set		% of Success		
Headset	Training Set	Set 1	Set 2	Set 3
Biosemi	User 1 Set 1	83.8303	62.2420	56.1927
	User 1 Set 2	67.5691	86.0887	63.0760
	User 1 Set 3	67.5729	67.1244	86.1547
	User 2 Set 1	75.7200	41.7915	48.1855
	User 2 Set 2	47.8588	79.0799	49.6238
	User 2 Set 3	54.1187	54.5507	79.0611
	User 3 Set 1	70.9988	45.3855	38.9603
	User 3 Set 2	49.9124	76.6939	39.6904
	User 3 Set 3	40.7267	37.8198	70.2616
Emotiv	User 1 Set 1	84.1004	35.8264	40.1151
	User 1 Set 2	40.6642	82.0868	40.2720
	User 1 Set 3	40.2092	41.0980	84.9150

Source: Prepared by the authors.

As can be observed, the Emotiv EPOC only shows a success rate on a regular FDA classification method in the order of 40%, which is comparable with the results obtained from the User 3 set of the BCI Competition.

However, the current quality of the classification stage is not sufficient to include the Emotiv headset in any control system. For this reason, other classifiers need to be evaluated. As the data sets from the BCI Competition III Set V are being used as a baseline to determine the quality of the signal the Emotiv EEG system provides, this set can be an excellent guideline to choose the best classifier too.

Then, using as a guide the BCI Competition III Set V data and the subsequent papers and studies, we propose to use a Neuro-Fuzzy S-dFasArt classification algorithm (Cano-Izquierdo et al 2012, 4).

As can be seen in the Table 2, the S-dFasArt+RP+VS gives the best results during the classification process with the same preprocessing mechanisms we have applied to our Emotiv set. For this reason, the following step in our research will be classifying the features coming from the Emotiv headset with the S-dFasArt algorithm.

Table 2: Comparison between the classification success rate with different methods using precomputed data of BCI Competition III

Method	Subject 1	Subject 2	Subject 3	Average
BCI-Competition Winner	79.60	70.31	56.02	68.65
	96 features	96 features	96 features	
S-dFasArt+RP+VS	<b>87.21</b>	<b>82.26</b>	<b>58.72</b>	<b>76.07</b>
	96 features	96 features	96 features	
S-dFasArt+RP+VS – GMDH	<b>89.50</b>	<b>82.49</b>	57.80	76.61
	4 features	4 features	3 features	

Source: (Cano-Izquierdo et al 2012, 5).

As well as increasing the classification success rate, we aim to use an Emotiv EPOC in a live on-line BCI control system. For that purpose, we need to minimize the load of processing required over the data on the pre-processing and classification stages. As different areas of the brain control different thoughts and actions, we want to determine the most relevant ones for our scenario to reduce the number of features to calculate, while maintaining the classification success rate (Arvaneh et al 2011, 1870)

### 3 CONCLUSION

In this paper a research to develop a BCI system based on EEG by using a low cost signal acquisition, pre-processing and classification system, has been presented. It is founded on previous successful results applying a Neuro-Fuzzy S-dFasArt method over the BCI Competition III set V carried out by the authors. It has been shown hopeful results by reducing drastically the number of characteristics taken into account to do the classification task. This methodology decreases the computational burden allowing an on-line processing and classification to deal with the Emotiv hardware with a small microprocessor.

## Reference list

- Mikhail A. Lebedev and Miguel A.L. Nicolelis. 2006. Brain-machine interfaces: past, present and future. *Trends in Neurosciences* 29: 536-546.
- J. del R. Millán, F. Galán, D. Vanhooydonck, E. Lew, J. Philips and M. Nuttin. 2009. Asynchronous Non-Invasive Brain-Actuated Control of an Intelligent Wheelchair. Engineering in Medicine and Biology Society. 2009. EMBC 2009. Annual International Conference of the IEEE.
- Emotiv. 2012. *Emotiv / EEG System / Electroencephalography*. <http://www.emotiv.com/store/sdk/bci/developer-edition-sdk/>
- Berlin Brain-Computer Interface. 2004. *BCI Competition III*. <http://www.bbc.de/competition/iii/>
- Dennis J. McFarland, Lynn M. McCane, Stephen V. David, Jonathan R. Wolpaw. Spatial filter selection for EEG-based communication. 1997. *Electroencephalography and clinical Neurophysiology* 103: 386-394.
- Fabio Babiloni, Febo Cincotti, Luigi Bianchi, Giada Pirri, Jose del R. Millán, Josep Mouriño, Serenella Salinari, María Grazia Marciani. Recognition of imagined hand movements with low resolution surface Laplacian and linear classifiers. 2001. *Medical Engineering & Physics* 23: 323-328.
- E. Iáñez, M.C. Furió, J.M. Azorín, J.A. Huizzi, E. Fernández. Brain-robot interface for controlling a remote robot arm. 2009. III International Work-Conference on the Interplay between Natural and Artificial Computation, IWINAC 2009, in: *Lecture Notes on Computer Sciences*, vol. 5602, Springer Verlag: 353-361.
- Yu-Te Wang<sup>1</sup>, Yijun Wang<sup>1</sup> and Tzyy-Ping Jung. A cell-phone-based brain-computer interface for communication in daily life. 2011. *Journal of Neural Engineering* 8.
- Autonomos Labs. 2012. *Brain Driver*. <http://autonomos-labs.com/>
- Jose-Manuel Cano-Izquierdo, Julio Ibarrola, Miguel Almonacid. Improving Motor Imagery Classification with a new BCI design using neuro-fuzzy S-dFasArt. 2012. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 20: 2-7.
- M. Arvaneh, C. Guan, K. Ang, and C. Quek. Optimizing the channel selection and classification accuracy in EEG-based BCI. 2011. *IEEE Transactions on Biomedical Engineering* 58: 1865-1873

## 2017 journal performance data for: Computational Intelligence and Neuroscience

ISSN: 1687-5265

eISSN: 1687-5273

HINDAWI LTD

ADAM HOUSE, 3RD FLR, 1 FITZROY SQ, LONDON W1T 5HF, ENGLAND

USA

## TITLES

ISO: Comput. Intell. Neurosci.

JCR Abbrev: COMPUT INTEL NEUROSC

## LANGUAGES

English

## CATEGORIES

MATHEMATICAL &amp; COMPUTATIONAL BIOLOGY - SCIE


Open Access from 2007

NEUROSCIENCES - SCIE


### 2017 Journal Impact Factor & percentile rank in category for: Computational Intelligence and Neuroscience

1,649

2017 Journal Impact Factor



### 2017 JIF citation distribution for: Computational Intelligence and Neuroscience



## Journal Impact Factor Calculation

$$\text{2017 Journal Impact Factor} = \frac{559}{339} = 1.649$$

How is Journal Impact Factor Calculated?

$$\text{JIF} = \frac{\text{Citations in 2017 to items published in 2015 (320) + 2016 (239)}}{\text{Number of citable items in 2015 (134) + 2016 (205)}} = \frac{559}{339}$$

## Journal Impact Factor contributing items

[Show all](#)[Citable items in 2016 and 2015 \(339\)](#)[Citations in 2017 \(559\)](#)

TITLE	CITATIONS COUNTED TOWARDS JIF
<a href="#">Prognostics of Lithium-Ion Batteries Based on Wavelet Denoising and DE-RVM</a>	51
By: Zhang, Chaolong; He, Yigang; Yuan, Lifeng; Xiang, Sheng; Wang, Jinping	
Volume: Page: Accession number: WOS:000361214600001 Document Type:Article	
<a href="#">Gait Planning and Stability Control of a Quadruped Robot</a>	19
By: Li, Junmin; Wang, Jing; Yang, Simon X.; Zhou, Kedong; Tang, Huijuan	
Volume: Page: Accession number: WOS:000374847200001 Document Type:Article	
<a href="#">Inversion for Refractivity Parameters Using a Dynamic Adaptive Cuckoo Search with Crossover Operator Algorithm</a>	10
By: Zhang, Zhihua; Sheng, Zheng; Shi, Hanqing; Fan, Zhiqiang	
Volume: Page: Accession number: WOS:000375580600001 Document Type:Article	
<a href="#">Nonlinear Inertia Weighted Teaching-Learning-Based Optimization for Solving Global Optimization Problem</a>	8
By: Wu, Zong-Sheng; Fu, Wei-Ping; Xue, Ru	
Volume: Page: Accession number: WOS:000361213200001 Document Type:Article	
<a href="#">EEG Classification for Hybrid Brain-Computer Interface Using a Tensor Based Multiclass Multimodal Analysis Scheme</a>	7
By: Ji, Hongfei; Li, Jie; Lu, Rongrong; Gu, Rong; Cao, Lei; et al.	
Volume: Page: Accession number: WOS:000370775100001 Document Type:Article	

## Key Indicators 2017



<b>Year</b>	2017	<b>5 Year Impact Factor</b>	1,678	<b>Cited Half-Life</b>	6,1	<b>Article Influence Score</b>	0,396	<b>Average JIF Percentile</b>	35,411
<b>Total Cites</b>	1,802	<b>Immediacy Index</b>	0,252	<b>Citing Half-Life</b>	6,9	<b>% Articles in Citable Items</b>	97,48		
<b>Journal Impact Factor</b>	1,649	<b>Citable Items</b>	119	<b>Eigenfactor Score</b>	0,00200	<b>Normalized Eigenfactor</b>	0,29100		
<b>Impact Factor Without Journal Self Cites</b>	1,595								

## Contributions by country/region



country	count
1. CHINA MAINLAND	247
2. USA	47
3. Italy	25
4. South Korea	23
5. Mexico	20
6. Japan	18
7. Spain	15
8. India	14
9. Taiwan	13
10. Turkey	12

## Contributions by organizations



organization	count
1. CHINESE ACADEMY OF SCIENCES	11
- NORTHWESTERN POLYTECHNICAL UNIVERSITY	11
3. NATIONAL UNIVERSITY OF DEFENCE TECHNOLOGY - CHINA	10
- ZHEJIANG UNIVERSITY	10
5. TONGJI UNIVERSITY	8
6. WUHAN UNIVERSITY	7
- NORTHEASTERN UNIVERSITY - CHINA	7
- FUDAN UNIVERSITY	7
- UNIVERSITY OF ELECTRONIC SCIENCE & TECHNOLOGY OF CHINA	7
10. HOHAI UNIVERSITY	6
- BEIJING JIAOTONG UNIVERSITY	6
- XI'AN UNIVERSITY OF TECHNOLOGY	6
- CENTRE NATIONAL DE LA RECHERCHE SCIENTIFIQUE (CNRS)	6
- PLA UNIVERSITY OF SCIENCE & TECHNOLOGY	6
- SHANGHAI JIAO TONG UNIVERSITY	6

## Research Article

# Feature Selection Applying Statistical and Neurofuzzy Methods to EEG-Based BCI

**Juan-Antonio Martinez-Leon, Jose-Manuel Cano-Izquierdo, and Julio Ibarrola**

*Universidad Politécnica de Cartagena, Campus Muralla del Mar, Calle Doctor Fleming S/N, 30202 Cartagena, Spain*

Correspondence should be addressed to Juan-Antonio Martinez-Leon; [jml16@alu.upct.es](mailto:jml16@alu.upct.es)

Received 8 December 2014; Revised 22 March 2015; Accepted 23 March 2015

Academic Editor: Christian W. Dawson

Copyright © 2015 Juan-Antonio Martinez-Leon et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

This paper presents an investigation aimed at drastically reducing the processing burden required by motor imagery brain-computer interface (BCI) systems based on electroencephalography (EEG). In this research, the focus has moved from the channel to the feature paradigm, and a 96% reduction of the number of features required in the process has been achieved maintaining and even improving the classification success rate. This way, it is possible to build cheaper, quicker, and more portable BCI systems. The data set used was provided within the framework of BCI Competition III, which allows it to compare the presented results with the classification accuracy achieved in the contest. Furthermore, a new three-step methodology has been developed which includes a feature discriminant character calculation stage; a score, order, and selection phase; and a final feature selection step. For the first stage, both statistics method and fuzzy criteria are used. The fuzzy criteria are based on the S-dFasArt classification algorithm which has shown excellent performance in previous papers undertaking the BCI multiclass motor imagery problem. The score, order, and selection stage is used to sort the features according to their discriminant nature. Finally, both order selection and Group Method Data Handling (GMDH) approaches are used to choose the most discriminant ones.

## 1. Introduction

Brain-computer interface (BCI) systems capture brain signals and decode them with the purpose of interacting with external devices without any muscular or physical intervention. Well-known examples are motor imagery tasks due to their importance in applications for severely motor impaired people. Likewise, other patterns can also be recognized within the brain signals, including word generation or object rotation. These patterns can be transformed to distinguishable signals and then to external commands or actions [1].

Technologically, most of the BCI mechanisms are based on electroencephalogram (EEG) techniques, where the sensors detecting the electric potentials originated by the neurons are placed on the scalp of the user [2]. Among the noninvasive technologies, where examples like magnetoencephalography (MEG), position emission tomography (PET), or functional Magnetic Resonance Imaging (fMRI) systems

can be considered, the main benefits of the EEG approach are the cost and the portability, making its use feasible in environments out of the laboratory. These systems show major benefits when being compared with invasive methods like electrocorticography (ECoG) [3] due to the fact that no brain surgery is being required to set up the montage.

According to how the brain signals get activated, two different paradigms can be distinguished [4, 5]. On the one hand, they can be produced spontaneously by human specific thoughts without any sensory stimulus. Examples of this comprise the detection EEG rhythms ( $\delta$ : 0–4 Hz,  $\theta$ : 4–8 Hz,  $\alpha$ : 8–12 Hz,  $\mu$ : 8–13, and  $\beta$ : 13–30 Hz) [6], slow cortical potentials (SCP), or event-related desynchronization (ERD)/event-related synchronization (ERS). On the other hand, the brain signals can be evoked by external stimulation, without prior training. Examples of the use of this method are the applications based on P300 [7], Steady-State Visual

Evoked Potential (SSVEP), or hybrid BCI systems combining both of them [8–10].

Because the recorded brain signals are so small in amplitude, EEG devices in particular present a very low signal to noise ratio (SNR). For this reason, any interference coming from sources such as eye movement, eye-blink, muscular movements, teeth clash, or the heart rhythm deeply affects the quality of the measured signal, which can prevent the decoding system from properly recognizing the intention of the user. As a consequence, an effort to improve the spatial filtering methods [11], the feature extraction techniques [12, 13], and the classification algorithms [14–16] has been undertaken by the scientific community.

In recent years, there has been increasing interest in minimizing the number of channels and features used by the classification algorithms. Yang et al. [17] identify three major drawbacks when using data from all channels by applying conventional ANNs, which can be extended to any EEG classifier: irrelevant features adding noise to the data and an increase in the complexity of the model and more computational burden. Other limitations can be added when considering the functional side and the cost of an EEG system. Tam et al. [18] measured the time to set up a 32-channel montage, achieving a total of 10–15 minutes when being done by an experienced operator (between 20 and 30 seconds per sensor). Regarding the cost, a public pricing list is available in [19] where doubling the number of electrodes seems to increase the overall cost of the system by around 25%.

There are a large number of published studies describing different approaches to feature and channel selection. These approaches comprise both wrapper and filter methods of feature selection. The most popular methods are Genetic Algorithms (GA) [17, 20, 21], Distinction Sensitive Learning Vector Quantizer (DSLQ) [22], Mutual Information algorithms (MI) [23], Fisher Criterion (FC) [1, 18, 24] methods, and Common Spatial Pattern (CSP) techniques [25, 26]. In addition, other approaches based on wavelet packet decomposition (WPD) [1] and combinations or evolutions of the previous methods like Rayleigh Coefficient and Genetic Algorithms [27], Sparse CSP (SCSP), Robust Sparse CSP (RSCSP) [28], or Mutual Information improvements as shown in [29, 30] have also been presented to the research community. Common to all of the studies, a direct relationship between the selected sensors and the expected cortical areas is shown, although different level of success has been attained.

In [18], a work is presented where the intention of movement detection is studied in stroke patients. The selection of a minimum number of electrodes allowing it to maintain a high success rate is suggested. For that purpose, two channel selection methods are proposed: Fisher Criterion and Support Vector Machine-Recursive Feature Elimination. From an initial number of 50 channels, it demonstrated that it is possible to select 12 electrodes while maintaining the performance. The Common Spatial Pattern algorithm has also been used to define methods of channel selection [25, 26]. In both works, data from the BCI Competition is used and it is shown that it is possible to maintain and

even improve the classification performance considerably reducing the number of used channels. In both scenarios, the channel selection is done by using the data in raw format before the feature extraction stage. An even more recent approach has been developed by Aler et al. [31], who present a new method for classification and feature selection, thus improving the preprocessing stage for the same data set and problem used in this paper.

Although extensive research has been carried out on feature selection, most of the available research has focused on reducing the number of channels required instead of the number of individual features. Also, no single study exists which adequately covers the result of implementing Statistical and Fuzzy approaches.

In Cano-Izquierdo et al. [14], the dFasArt is proposed as a neurofuzzy model for the self-organised learning whose defined clusters are determined by the weights of the units, which can be interpreted as rules on fuzzy sets. The connections between the units of the model and the value of the weights define a Fuzzy Logic System (FLS). Among the characteristics of the dFasArt, it is worth highlighting the way the clustering works according to the incoming values and their arrival sequence to the system. Also, the system can work with ambiguous or noisy data.

Later work [32] presents a methodology to undertake the motor imagery problem. A supervised version of the dFasArt (S-dFasArt) is added including the creation of different models from the learning sessions, a rule prune stage (which allows the reduction of the number of units of the models learning from the classification error on the learning sessions), and a later voting phase among the different models. This approach was successfully applied to the Data Set V of the BCI Competition.

The data processing on the BCI Competition data sets is always off-line. If the methods included on the literature were to be applied on live applications, the time constraints to produce a prediction would be a major issue to address. For instance, for the Data Set V, it is necessary to calculate the PSD function for 8 sensors and 12 frequency bands (96 features) and then apply the recognition logic 16 times per second. Moreover, there is a requirement of producing a prediction every 0.5 seconds. This computational burden requirement is not easily accommodated even on today's PCs. For on-line applications, reduction of the number of features to process is necessary.

This paper introduces a new methodology to choose the most relevant features using different approaches, being the statistic properties of the data or the relationship between the fuzzy categories which are generated on a S-dFasArt model. These methods have been applied to the Data Set V available for BCI Competition III [33] showing a reduction from 96 to 4 (96%) in the number of features required to maintain the output accuracy of the system when using a Fuzzy and GMDH (Group Method Data Handling) methodology.

The remainder of this paper is organized as follows. Section 2 describes the data set format and structure. The methods applied are explained in Section 3. Section 4 details the results obtained. The validation of the results and






FIGURE 1: Image of the montage applying the 10-20 system convention.

a comparison with other literature results are presented in Section 5 and finally Section 6 concludes this paper.

## 2. Data Sets Description

The work presented in this paper is based on the Data Set V available for the BCI Competition III [33] organized in 2004 by the Berlin brain-computer interface area of Berlin Institute of Technology. It is aimed to use this contest as both benchmark source and data source. For this reason, the same rules defined by the BCI Competition organizers have been followed, allowing us to compare the results attained by the research community with those presented on this paper. This implies using the designated sensors and maintaining the algorithms used at the preprocessing stage.

The data set was provided by the IDIAP Research Institute of Switzerland and undertakes the multiclass motor imagery problem. This set was recorded by a Biosemi system using a cap with 32 integrated electrodes located at standard positions of the International 10-20 system as depicted in Figure 1. The sampling rate was 512 Hz, the signals were acquired at full DC, and no artifact rejection or correction was employed.

This data set focuses on a benchmark to classify three mental tasks [34]: left hand movement, right hand movement, and generation of words beginning with the same random letter. All sessions were obtained from healthy users with no previous EEG or mental training. The recordings were

completed during the same day, each lasting 4 minutes, with 5–10 minutes breaks between them. The users were required to think about one of the three defined tasks with intervals of 15 s. Processed data from 3 of them, who recorded 4 sessions each, is used.

The precomputed sets provided only include the sensors C3, Cz, C4, CP1, CP2, P3, Pz, and P4 out of the available 32 and they are the result of several transformations of the raw data. In the first stage, the potentials recorded were spatially filtered by means of a surface Laplacian. After that, a Power Spectral Density (PSD) calculation for the frequency band between 8 and 30 Hz with a resolution of 2 Hz was performed. Being the sampling frequency 512 Hz and the records divided in windows of 1 s with an additional rate of 32 samples, an overlapping of 93.75% between windows is defined.

The computational burden of this processing can be calculated as the product of 12 different features (or different frequencies bands) per sensor by 8 channels, involving a total of 96 features per sample, yielding 49,152 features per minute.

To facilitate the understanding of the results presented in this paper, Table 1 shows the exact equivalence between the component number selected from the feature vector and the channel and frequency associated with it.

Out of the four available BCI Competition data sets per user, there are three learning data sets and a final one for testing. The learning sets are used to calculate the number of features selected by each one of the models,

TABLE 1: Channel and frequency associated with each feature in the input vector.

Channel	Frequency (Hz)											
	8	10	12	14	16	18	20	22	24	26	28	30
C3	1	2	3	4	5	6	7	8	9	10	11	12
Cz	13	14	15	16	17	18	19	20	21	22	23	24
C4	25	26	27	28	29	30	31	32	33	34	35	36
CP1	37	38	39	40	41	42	43	44	45	46	47	48
CP2	49	50	51	52	53	54	55	56	57	58	59	60
P3	61	62	63	64	65	66	67	68	69	70	71	72
Pz	73	74	75	76	77	78	79	80	81	82	83	84
P4	85	86	87	88	89	90	91	92	93	94	95	96

while the additional test session is only used at a later stage (Section 4) to validate the quality of the calculated model. Just to reiterate, the calculations presented in this paper are based on the data from the C3, Cz, C4, CP1, CP2, P3, Pz, and P4 sensors.

### 3. Methods

For the purpose of reducing the size of the features vector, a new methodology has been developed. Initially, the size of the features vector is the result of multiplying the number of channels used in the analysis by the number of frequencies considered in the PSD calculation. The classification method used is based on the S-dFasArt architecture proposed by Cano-Izquierdo et al. [32], which shows superior performance to other proposals for the multiclass motor imagery problem. It is intended that the feature selection method and the classification algorithm complement each other to maintain the overall system performance. This way, the global classification success rate can be used as a baseline, which needs to be maintained while significantly reducing the input vector.

Figure 2 presents the main stages of the selection process, which obtains a reduced set from all the initial features available in the input vector (96 in this case).

(1) *Feature Discriminant Character*. At this step, the discriminant capacity of every feature is determined. Two methods are proposed.

(i) *Statistics Method*. It is based on statistical results normally used in pattern recognition problems. This criterion only depends on the data.

(ii) *Fuzzy Criteria*. It is supported by the S-dFasArt architecture as a Fuzzy Logic System, which includes a set of rules to link fuzzy sets. Therefore, this criterion is affected by both the input data and the neurofuzzy model, which is defined by the rules calculated from the data.

(2) *Score, Order, and Selection*. For this study, a feature preselection method based on the obtained discriminant character of the data is introduced. First, the discriminant




FIGURE 2: Feature selection proposed methodology.

value of every feature is assessed and the feature itself is scored from 1 to 10, with 10 indicating the most and 1 the least discriminant feature. After that, all of them are sorted in descending order according to the scores given.

Then, all the scores are added according to each feature, allowing the creation of a feature classification from most to least discriminant nature. Using this ranking, a first selection of the candidate features to form the reduced vector is obtained.

(3) *Feature Selection*. In this stage, those features yielding the best performance when using the neurofuzzy classifier are selected from the candidate features set. In order to obtain the best performing subset, two different methods are proposed.

(i) *Order Selection*. By sorting the preselected features vector according to the given SCORE,  $(x_1, \dots, x_D)$ , only  $D$  possible feature vectors are considered  $\{(x_1), (x_1, x_2), (x_1, x_2, x_3) \dots (x_1 \dots x_D)\}$ . The accuracy of every individual option is calculated by applying a  $k$ -fold method with the three available learning sessions and the S-dFasArt classifier. After that, the best performing features vector will be chosen.

(ii) *Group Method Data Handling (GMDH)*. This selection method evaluates the features to be added to the subset according to a Regularity Criterion (RC).

3.1. *Feature Discriminant Character*. Two methodologies, based on the training data sets, are evaluated to analyze the discriminant nature of each of the components of the feature vector: the first one is supported by applying classic statistics methods, while the second is based on the fuzzy logic interpretation of the classifier which gets created from the training data set.

3.1.1. *Statistics Method for Feature Selection*. The framework on this research can be defined as a classification problem

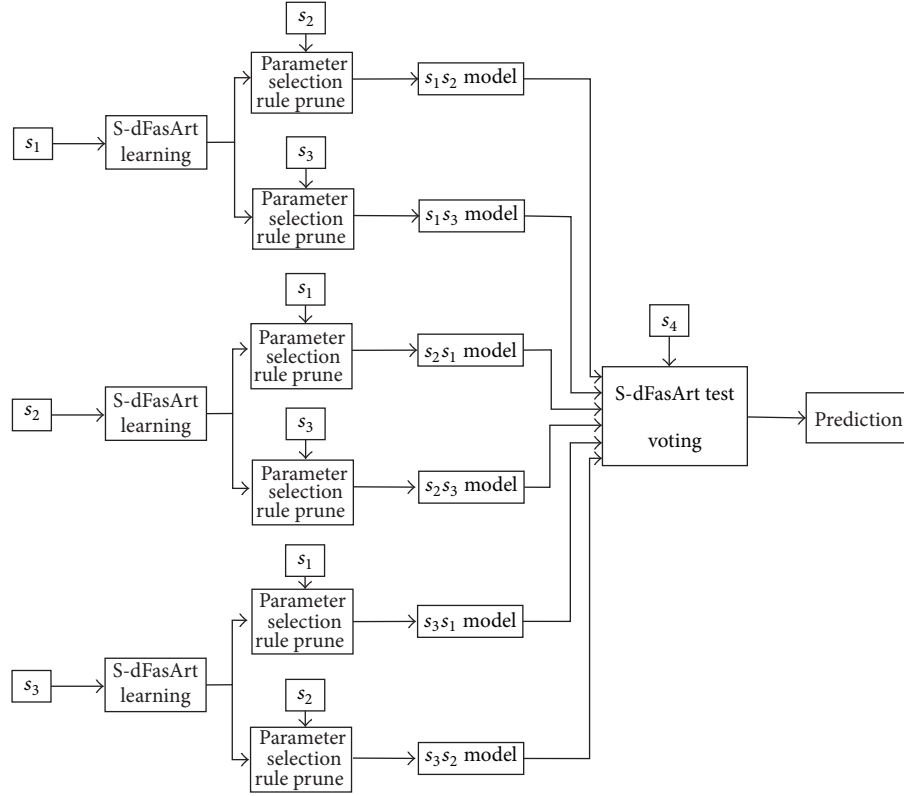


FIGURE 3: S-dFasArt classification process.

of  $M$ -dimensions in  $C$  classes. According to this premise, a set of vectors which are assumed to be “properly” classified is used and is denoted as the learning set. By using the learning set, the relative contribution for each of the features on the sampling vector to the class separability is studied. As a consequence, the properties of the statistic results from the learning vector set are calculated [35].

$\gamma_{ij}$  is denoted as the variance for the  $j$ th feature in the  $i$ th class,  $P_i$  the a priori probability of the  $i$ th class, and  $\lambda_j$  the total value of the variance of the  $j$ th feature. The normalized variance can be defined as

$$\tilde{\gamma}_{ij} = P_i \frac{\gamma_{ij}}{\lambda_j}. \quad (1)$$

When establishing the criteria to determine the discrimination capacity contribution of each of the features, the statistical entropy can be estimated as

$$J(x_j) = \sum_{i=1}^C \tilde{\gamma}_{ij} \log(\tilde{\gamma}_{ij}). \quad (2)$$

Alternative criteria to show the discriminant information of each feature can be defined as

$$J(x_j) = \prod_{i=1}^C \tilde{\gamma}_{ij}. \quad (3)$$

This expression has a maximum value of  $(1/C)^C$  when all the values of  $\tilde{\gamma}_{ij}$  are the same for a certain feature  $i$ . In this scenario, it can be concluded that the feature  $i$  does not add discriminant information and it can be dismissed.

**3.1.2. Fuzzy Criteria for Feature Selection.** An architecture to classify EEG data applying the same benchmark as proposed in the BCI Competition Data Set V is proposed by Cano-Izquierdo et al. [32], whose output accuracy has demonstrated the ability to improve any other results published so far. The recognition system is based on the use of a neurofuzzy S-dFasArt model [14] and on a three-stage methodology, which intends to increase the utility of the three available learning sessions (Figure 3).

- (1) First, a learning session is used to generate a rule set defining the model.
- (2) After that, a different learning session is devoted to adjust the model parameters to be applied at the test stage. Then, a rule prune is performed where the rules contributing to a higher error than success rate are discarded.
- (3) Finally, once all the possible combinations of the three learning sessions are used for stages 1 and 2, there are six models available. For each one, 16 vectors per second are processed. Then, due to the fact that a prediction is produced every half a second only,

every model contributes to 8 possible alternatives. To choose among the  $48 = 6 \times 8$  possible predictions, a voting strategy is used where the most frequent prediction is selected.

For the purpose of feature selection, the third stage of the model is replaced by an “intermediate” model, which is defined with only three rules (each one associated with one single class). To do this, the weights defining every rule are calculated as the mean of the weights predicting the same category. The S-dFasArt model allows each class to be interpreted as a rule whose transference function is determined by the weights associated with fuzzy sets. Moreover, the rule associated with the  $i$  class of each feature  $j$  is represented by a fuzzy set  $A_j^i$  as follows:

$$\text{IF } x_1 \text{ IS } A_1^i \text{ AND } x_2 \text{ IS } A_2^i \text{ AND } \dots \text{ AND } x_{96} \text{ IS } A_{96}^i. \quad (4)$$

Also, it is assumed that the discriminant character of each feature will be linked to the relationship between its associated fuzzy sets for two classes. If these fuzzy sets are very similar, the feature will not be very discriminant. If the fuzzy sets are clearly different, the discriminant character of the feature will increase.

For each feature, the discriminant character is obtained by comparing the corresponding fuzzy sets for two rules  $i$  y  $k$ , by using the expression:

$$F(x_j) = \frac{|A_j^i \wedge A_j^k|}{|A_j^i \vee A_j^k|}. \quad (5)$$

A value of  $F(x_j)$  near to zero denotes a very discriminant feature while a value approaching one denotes a very low discriminant feature.

**3.2. Score, Order, and Selection.** To determine the minimum number of features that can be part of the system while maintaining the output accuracy, the criteria based on the accumulated scores with regard to the total punctuation are presented. The scores are calculated by using both statistics method and fuzzy criteria. After that, the features are sorted in a descending order and the number of candidate features to be part of the model  $K$  is calculated as follows:  $K = \min\{k\}$  which fulfills

$$\frac{\sum_{j=1}^k \text{SCORE}(j)}{\sum_{j=1}^M \text{SCORE}(j)} > \rho. \quad (6)$$

The design parameter  $\rho$  is adjusted to discard any feature whose SCORE value is the minimal.

### 3.3. Feature Selection

(1) *Order Selection.* The different models are being determined by selecting an increasing number of features according to the established relevance order.

(2) *Group Method Data Handling (GMDH).* This methodology is based on the definition of a Regularity Criterion




FIGURE 4:  $s_i s_j s_k$  model generation.

(RC) [36], which is calculated for different candidate models, starting from single feature models. RC is considered to be the average success rate of the models for the 6 possible combinations of  $(i, j, k)$   $s_i s_j s_k$  as shown in Figure 4. Using single variable models as a starting point, the highest RC value is chosen. After that, a new feature is added and the model with the highest RC value is selected again. When the RC of the extended model is higher than the previous one, this one is selected as a baseline for a new iteration. When the maximum value of RC for the different models is less than the previous one, the model cannot expand and the method stops.

## 4. Results

This section summarizes the outcome of the application of the previous methodology and architecture to the BCI Competition III Data Set V database, addressing a three-class classification problem. First, the application of the statistics method is presented and the results for both Order and GMDH Selection are shown in different figures and tables. Then, the analogue information is shown for the methods based on fuzzy criteria. Section 5 joins the results of both approaches and compares them.

**4.1. Statistics Method for Feature Selection.** Figure 5 provides the results obtained for the three users of the BCI Competition III Data Set V database. The value of  $J(x_j)$  has been calculated in a separate way for each one of the three learning sessions within the data. Given that the lower values on the figures are related to high discriminant features, the existence of a reduced number of features with a high discriminant character can be stated.

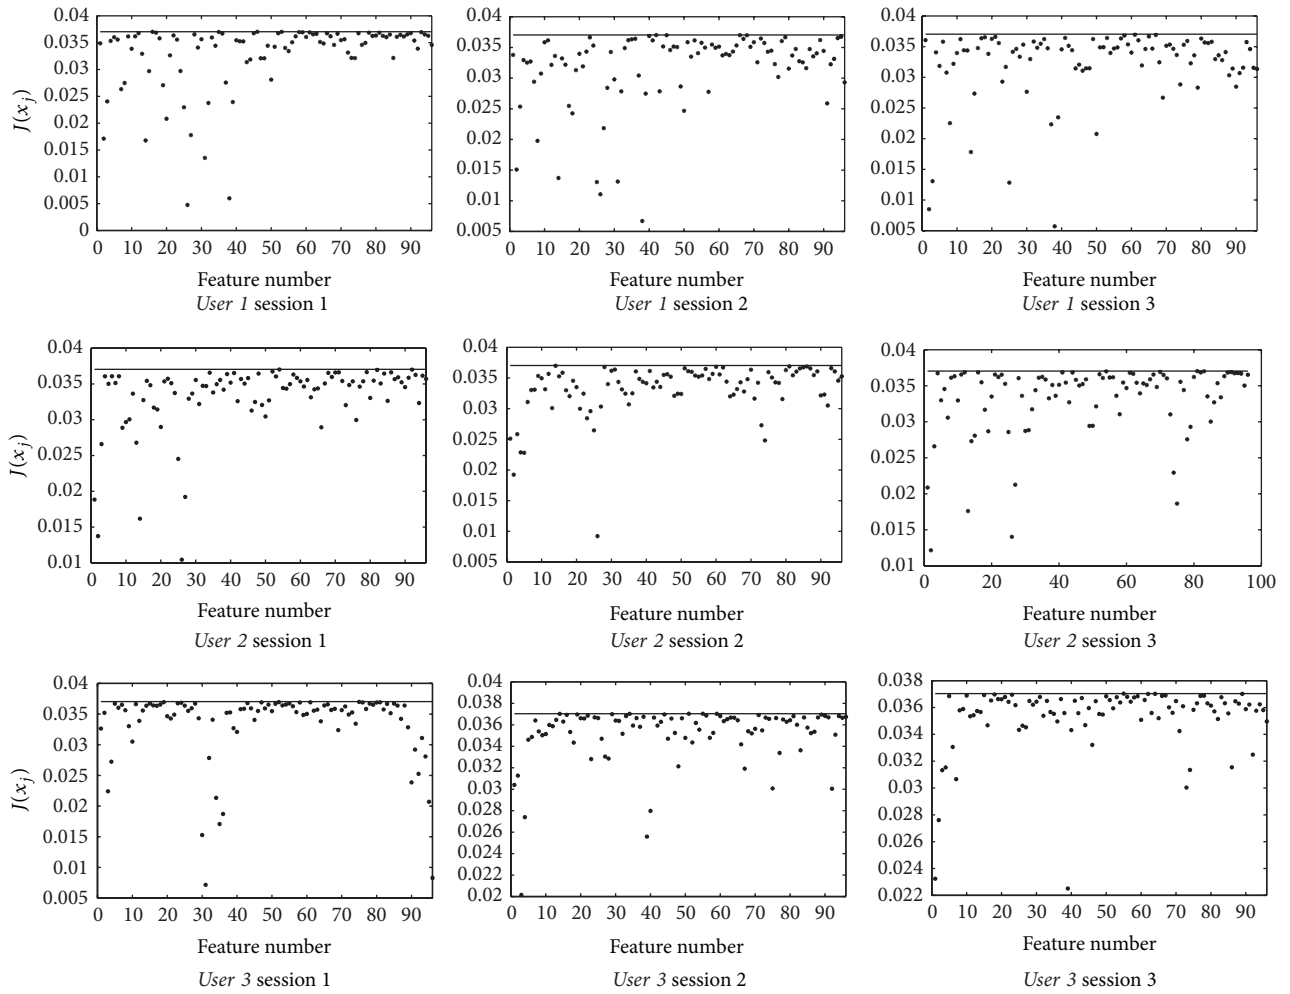
To determine the most discriminant features, they have been ordered from higher to lower value of  $J(x_j)$ . Only the first 10 are considered and a score from 10 to 1 is assigned according to the achieved position. Once the marks from the three learning sessions are added up, the final results are gathered in Figure 6. As can be seen, the discriminant nature seems to be confined within a small number of features. Table 2 shows the channel information and frequencies related to the ten most relevant features for each user.

The numbers of candidate features obtained after applying the 85% criteria for each of the three studied users results are  $K = 9$  for *User 1*,  $K = 10$  for *User 2*, and  $K = 15$  for *User 3*.

**4.1.1. Order Selection.** The results are presented in Table 3. For *User 1*, the best value of the classification success rate is achieved when using the two highest scored features. These are 38 and 2 of the input vectors, which relate to CPI-10 Hz

TABLE 2: Features, channels, and related frequencies.

<i>User 1</i>										
Feature	38	2	14	25	26	31	27	3	8	50
Channel	CP1	C3	Cz	C4	C4	C4	C4	C3	C3	CP2
Freq/Hz	10	10	10	8	10	20	12	12	22	10
<i>User 2</i>										
Feature	26	2	1	3	13	27	14	74	5	25
Channel	C4	C3	C3	C3	Cz	C4	Cz	Pz	C3	C4
Freq/Hz	12	10	8	12	8	12	10	10	16	8
<i>User 3</i>										
Feature	39	3	1	2	4	31	96	30	92	35
Channel	CP1	C3	C3	C3	C3	C4	P4	C4	P4	C4
Freq/Hz	12	12	8	10	14	20	30	18	22	28

FIGURE 5:  $J(x_j)$  values for the three users and sessions. The value  $(1/C)^C$  is represented by a solid line.

and C3-10 Hz as shown in Table 2. Therefore, the results calculated for *User 1* can be presented as

$$X = (x_{38}, x_2). \quad (7)$$

Following the same criteria, *User 2* selected features would be as follows:

$$X = (x_{26}, x_2, x_1), \quad (8)$$

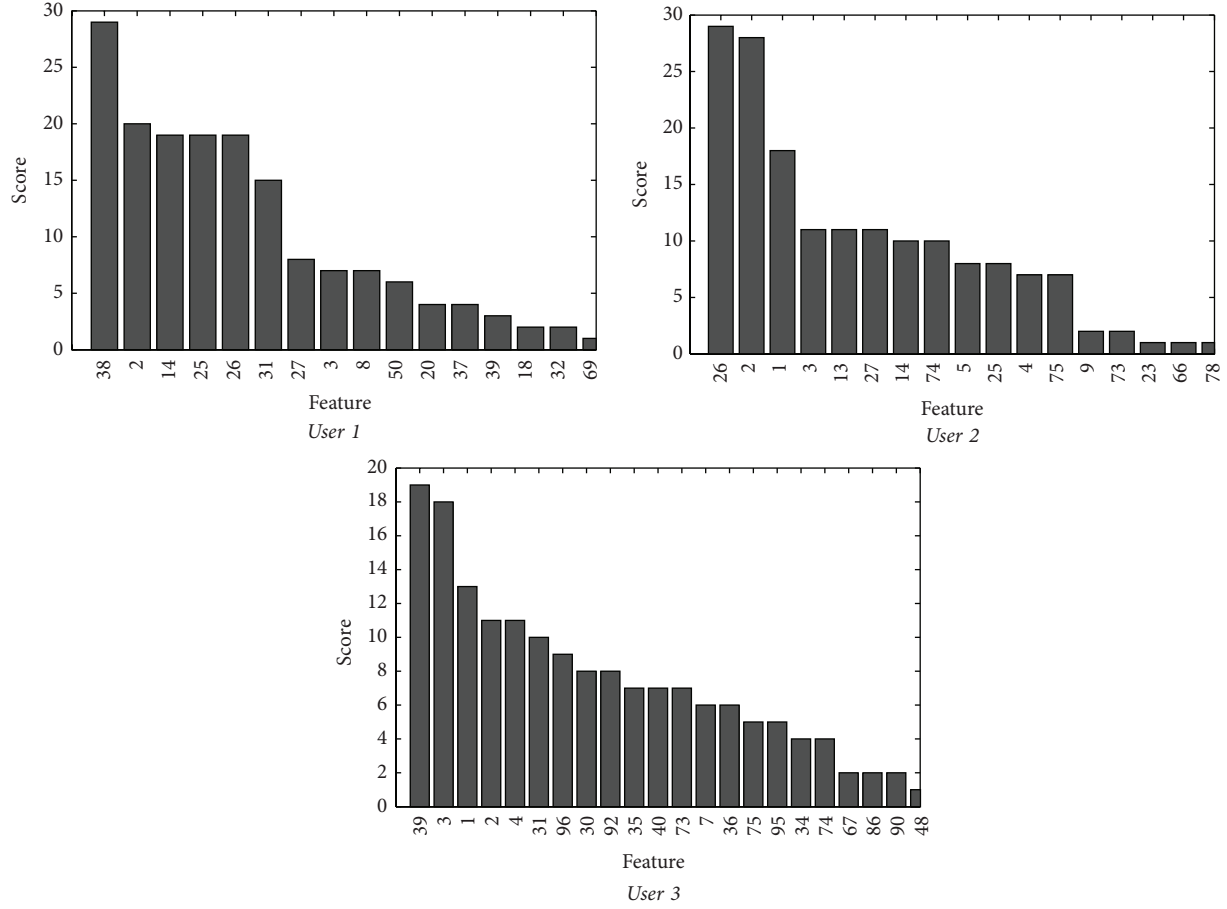


FIGURE 6: Relevance classification based on the score calculated from the discriminant nature of each feature.

whereas for *User 3* the features would be represented as follows:

$$X = (x_{39}, x_3, x_1, x_2, x_4, x_{31}). \quad (9)$$

**4.1.2. GMDH Selection.** Table 4 shows the selected models and their RC values.

**4.2. Fuzzy Criteria for Feature Selection.** Figure 7 compares the discriminant character of the features for the three users by using session 1 for learning and session 2 for adjustment and rule prune. Similar results are attained when the other five combinations between the learning and the adjustment sets are calculated.

If the features are sorted from the highest to lowest value of  $F(x_j)$  and only the ten most important ones are selected, assigning them scores from 10 to 1 and adding them up for the six possible scenarios, the results displayed by Figure 8 are obtained.

When applying the 85% criteria on the value of  $K$ ,  $K_1 = 9$  (*User 1*),  $K_2 = 11$  (*User 2*), and  $K_3 = 16$  (*User 3*).

The best ten channels and the frequency value attached to them for every user are provided in Table 5.

**4.2.1. Order Selection.** Table 6 presents the different results when considering this model with an increasing number of features.

From them, the input vector for *User 1* can be presented as

$$X = (x_{26}, x_{27}, x_{25}, x_{38}, x_2, x_3, x_{61}, x_{39}, x_{62}), \quad (10)$$

while for *User 2* it would be

$$X = (x_{26}, x_2, x_1). \quad (11)$$

And for *User 3* it is as follows:

$$X = (x_3, x_{74}, x_{39}, x_4, x_{73}). \quad (12)$$

**4.2.2. GMDH Selection.** Analogously to the process followed for the statistic criteria, the GMDH method will be used with the purpose of selecting a model from a candidate feature set. In Table 7, the selection process and the final selected features are shown.

## 5. Final Validation and Discussion

It is fundamental to outline that the test set of the BCI Competition is first used in the calculations required to obtain



TABLE 3: Success rate (in %) as a function of the input vector dimension ( $M$ ) applying the statistics method and order selection.  $s_i s_j s_k$ :  $i$  learning session,  $j$  rule prune session, and  $k$  test session.

$M$	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Average
<i>User 1</i>							
1	68.25	59.83	68.58	59.78	66.91	67.86	65.20
2	86.24	79.06	87.72	73.48	79.03	75.17	<b>80.12</b>
3	85.96	78.40	85.26	67.66	79.41	69.15	77.64
4	84.84	79.15	87.08	66.80	81.94	65.17	77.50
5	77.05	78.40	79.74	62.44	71.51	64.71	72.31
6	74.52	77.13	79.40	54.30	73.62	66.40	70.90
7	78.17	72.18	80.13	76.63	76.90	74.00	76.34
8	77.66	76.87	80.77	63.88	77.10	78.44	75.79
9	80.10	77.53	81.25	72.65	76.84	77.69	77.68
<i>User 2</i>							
1	44.82	62.56	57.60	46.00	59.09	49.91	53.33
2	62.56	71.44	72.90	67.34	78.91	67.63	70.13
3	68.69	75.43	72.00	68.52	75.98	63.82	<b>70.74</b>
4	61.18	65.08	78.25	65.41	64.53	63.25	66.28
5	67.40	67.33	71.34	55.88	69.97	64.11	66.01
6	62.96	67.45	72.44	65.67	73.76	63.77	67.68
7	61.38	68.37	65.90	58.44	64.61	58.52	62.87
8	62.13	61.34	69.59	53.74	67.88	63.62	63.05
9	62.76	64.58	67.91	56.94	63.28	60.54	62.67
10	62.44	68.14	67.08	56.02	74.57	51.58	63.31
<i>User 3</i>							
1	38.60	28.27	00.00	42.73	38.61	34.55	30.46
2	42.12	54.23	45.55	45.12	50.85	47.37	47.54
3	42.41	38.00	51.83	45.94	49.15	41.85	44.86
4	40.12	52.75	49.10	47.90	50.38	48.39	48.11
5	41.45	54.91	50.29	49.45	50.47	48.60	49.20
6	43.43	50.55	48.31	49.04	55.75	56.92	<b>50.67</b>
7	42.06	50.32	47.30	47.37	54.47	49.53	48.51
8	40.64	48.31	44.39	45.74	50.15	49.36	46.43
9	42.35	53.27	44.88	44.16	49.85	47.78	47.05
10	40.55	58.97	43.08	44.92	53.65	50.00	48.53
11	46.05	51.29	44.27	41.91	52.95	51.66	48.02
12	47.91	54.96	44.59	50.03	48.10	54.47	50.01
13	46.69	50.73	46.48	45.71	50.64	52.25	48.75
14	44.27	55.34	50.73	48.16	44.71	52.69	49.32
15	42.59	47.75	44.30	50.82	49.47	51.52	47.74

the results presented in this section. In previous sections, only the learning session data sets are applied. In order to check the efficiency of the proposed methodology, a final stage has been performed following the method developed in [32] (Learning-Prune-Voting) with no additional parameter adjustment. The results obtained from the previous stage are shown in Table 8.

The most striking result to emerge from the data is that a reduction from a total of 96 to a range between 3 and 9

features is achieved. Interestingly, the classification success rate is maintained or even slightly improved while reducing the number of features.

Aler et al. [31] also present a feature selection process over this same data set. However, their focus is based on selecting frequency bands across all channels, so the numbers shown should be multiplied by 8 in order to be comparable with the ones above yielding  $4 \times 8 = 32$  features for *User 1*,  $2 \times 8 = 16$  for *User 2*, and  $5 \times 8 = 40$  for *User 3*. As can be seen, they

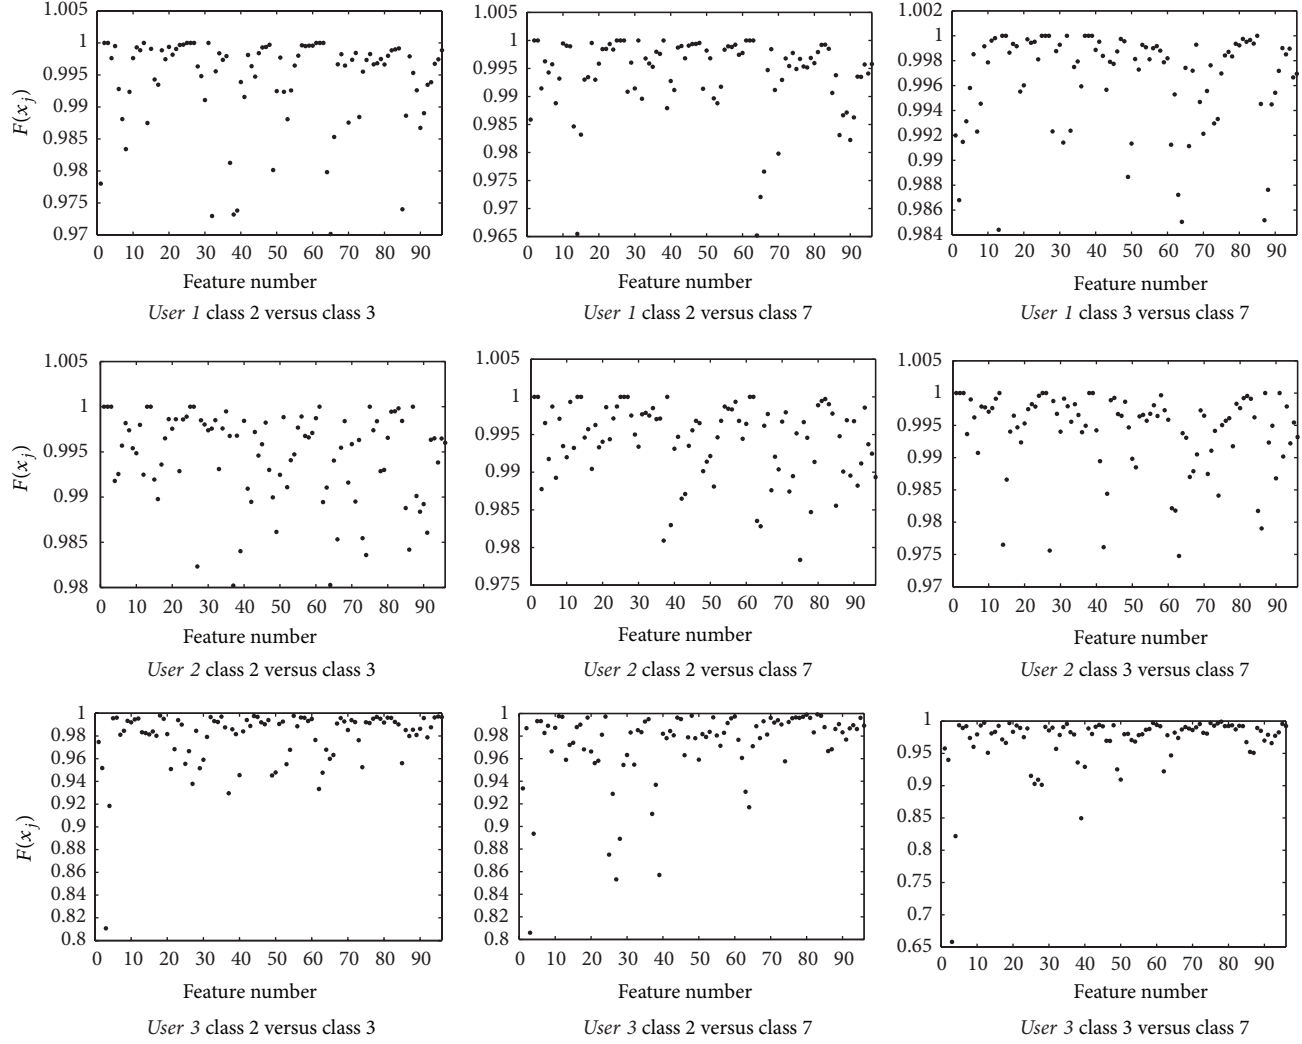


FIGURE 7:  $F(x_j)$  values for the three users using session 1 for learning and session 2 for parameter adjustment and rule prune. Class “2” identifies the “LEFT” task, “3” represents “RIGHT” and “7” corresponds to “WORD”.

TABLE 4: Features and RC values for the models calculated for the different users based on GMDH selection for statistics method scored data.

Features	RC
<i>User 1</i>	
$\{x_{38}\}$	67.96
$\{x_{38}, x_2\}$	80.12
$\{x_{38}, x_2, x_{31}\}$	<b>80.95</b>
<i>User 2</i>	
$\{x_2\}$	57.22
$\{x_2, x_{26}\}$	70.13
$\{x_2, x_{26}, x_5\}$	<b>72.72</b>
<i>User 3</i>	
$\{x_4\}$	49.58
$\{x_4, x_3\}$	51.70
$\{x_2, x_3, x_{30}\}$	<b>53.34</b>

are much higher than the ones presented here. Another point to consider is the fact that the classification success rate presented in this paper is about 10 points higher for *Users 1 and 2*.

Similarly, another approach for feature selection is presented in [37]. In this occasion, EEG maps are created as a geometrical representation of the activity of the precomputed data of the Data Set V and only 1 frequency is selected for each user (10 Hz for *User 1*, 10 Hz for Subject 2, and 12 Hz for Subject 3). Given that data was collected by using 8 sensors, each map includes information from 8 features. Also, the amount of data used to create the map is 5 seconds, compared to the 1 second window allowed by the BCI Competition rules. Even in that advantageous situation, the classification success rate achieved is still 1.60 points lower than the Statistical and GMDH approaches.

A comparison among the classification success rate of the BCI Competition Winner, the results presented in [31, 37], and the results of this paper is shown in Table 9.



TABLE 5: Features, channels, and related frequencies.

<i>User 1</i>										
Feature	26	27	25	38	2	3	61	39	62	14
Channel	C4	C4	C4	CP1	C3	C3	P3	CP1	P3	Cz
Freq/Hz	10	12	8	10	10	12	8	12	10	10
<i>User 2</i>										
Feature	2	26	1	25	74	27	3	14	73	13
Channel	C3	C4	C3	C4	Pz	C4	C3	Cz	Pz	Cz
Freq/Hz	10	10	8	8	10	12	12	10	8	8
<i>User 3</i>										
Feature	3	74	39	4	73	27	25	1	86	26
Channel	C3	Pz	CP1	C3	Pz	C4	C4	C3	P4	C4
Freq/Hz	12	10	12	14	8	12	8	8	10	10

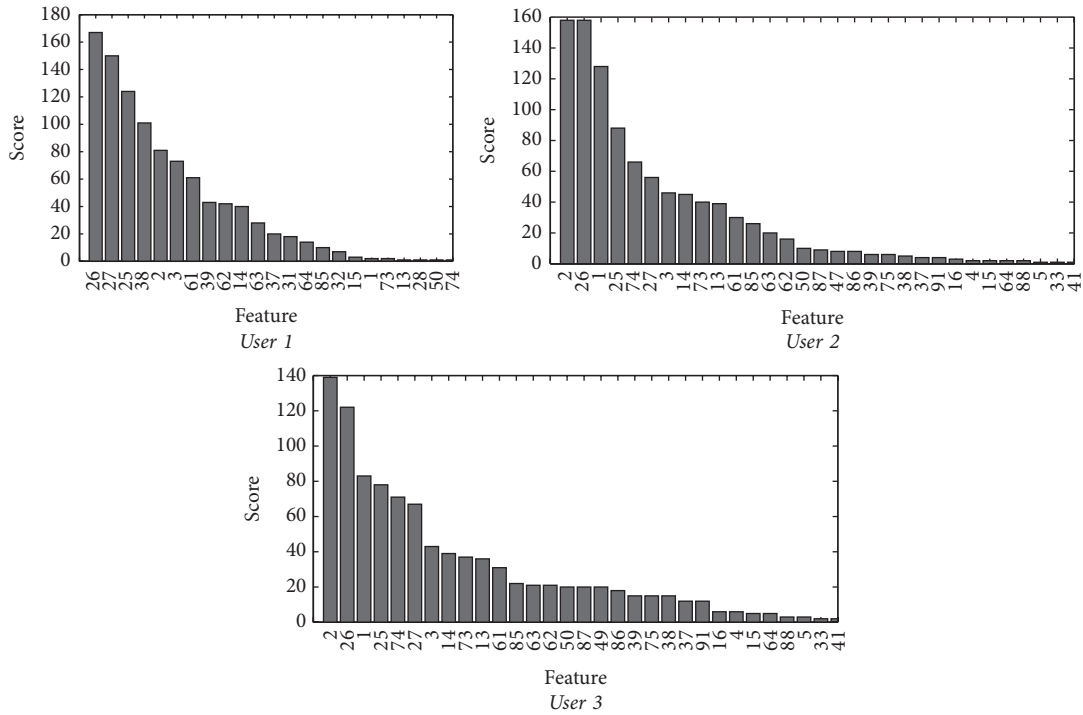


FIGURE 8: Relevance classification based on the score calculated from the discriminant nature of each feature.

It is apparent from Table 8 that there is a subset of features appearing in all the selection methods for a certain user. For instance, features  $x_{38}$  and  $x_2$  are common to all models for *User 1* while  $x_{26}$  and  $x_2$  appear in all selection methods for *User 2* and  $x_3$  and  $x_4$  are common across the models calculated for *User 3*.

The correlation between the selected features and the users has been tested too. However, a set of common features cannot be generalized. The results show how  $x_2$  appears in all methods for *Users 1 and 2*, but it is not a part of the selected

features for *User 3* by the Fuzzy selection methods. Also, it is certainly difficult to find features adopted for all users within the same selection method. As an example, for the Fuzzy + GMDH selection method,  $x_2$  and  $x_{27}$  are selected for *Users 1 and 2*, but they do not seem to have the same relevance for *User 3*.

Turning now to the channel position associated with the selected features (Figure 1), it can be clearly noted that important channels not only locate on the lateral area of the motor cortex, but also in the centre zone between them.

TABLE 6: Success rate (in %) as a function of the input vector dimension ( $M$ ) applying the fuzzy criteria and order selection.  $s_i s_j s_k$ :  $i$  learning session,  $j$  rule prune session, and  $k$  test session.

$M$	$s_1 s_2 s_3$	$s_1 s_3 s_2$	$s_2 s_1 s_3$	$s_2 s_3 s_1$	$s_3 s_1 s_2$	$s_3 s_2 s_1$	Average
<i>User 1</i>							
1	49.78	55.62	39.27	40.54	54.21	58.60	49.67
2	56.98	66.04	60.17	55.39	70.28	71.65	63.42
3	65.30	60.17	65.98	59.32	67.40	59.46	62.94
4	78.08	73.73	78.78	65.14	74.02	70.53	73.38
5	78.76	73.44	80.47	78.35	77.45	69.58	76.34
6	79.71	70.19	80.63	76.86	77.85	65.97	75.20
7	79.23	78.51	78.62	58.97	79.98	68.15	73.91
8	79.07	77.79	79.48	71.62	76.50	69.47	75.66
9	80.30	79.00	80.04	66.37	81.08	81.07	<b>77.98</b>
<i>User 2</i>							
1	34.48	58.33	65.87	66.07	60.94	57.63	57.22
2	62.56	71.44	72.90	67.34	78.91	67.63	70.13
3	68.69	75.43	72.00	68.52	75.98	63.82	<b>70.74</b>
4	61.43	63.31	70.56	59.50	69.53	62.33	64.44
5	61.46	70.05	67.17	59.65	63.54	53.74	62.60
6	58.06	69.70	72.87	58.41	61.83	62.07	63.83
7	68.03	65.74	65.84	58.38	45.60	61.95	60.92
8	65.01	62.24	50.60	43.98	70.95	58.67	58.58
9	68.15	66.20	62.41	48.10	66.30	58.64	61.63
10	65.67	66.41	65.15	63.59	66.26	56.45	63.92
11	52.33	67.36	68.63	58.27	56.57	55.90	59.84
<i>User 3</i>							
1	42.50	54.61	34.65	46.41	54.47	45.59	46.37
2	41.28	36.01	40.17	46.82	49.97	46.82	43.51
3	43.87	48.60	44.22	46.90	48.01	46.06	46.28
4	44.39	53.21	41.95	48.83	51.26	48.48	48.02
5	45.17	54.38	42.88	44.89	53.91	49.45	<b>48.45</b>
6	42.67	51.26	43.90	47.14	56.89	47.20	48.18
7	39.85	56.75	41.10	42.73	48.57	44.57	45.60
8	41.16	54.56	43.69	46.73	45.39	45.59	46.19
9	42.03	50.29	40.38	43.55	46.47	45.85	44.76
10	41.31	50.32	38.75	43.43	44.10	38.70	42.77
11	40.32	45.97	38.49	48.16	44.71	44.60	43.71
12	41.19	50.18	44.62	41.44	42.79	45.24	44.24
13	42.01	44.80	36.31	42.03	44.92	41.65	41.96
14	41.69	47.81	41.69	47.96	45.74	41.44	44.39
15	41.42	51.90	39.22	46.99	42.41	43.05	44.17
16	40.23	41.12	37.65	43.49	39.08	43.87	40.91

Table 10, which includes all the relevant features for all users when applying a Fuzzy + GMDH feature reduction method, clearly shows that all the selected features belong to the  $\alpha$  and  $\beta$  rhythms. Also, the importance of the C3 is common to all users while C4 only appears to be useful for *Users 1 and 2*. Besides, other channels and frequencies appear

to be relevant too. For instance, the  $\alpha$  frequencies of the CP1 and CP2 sensors seem to be significant for *Users 1 and 3*, while  $\alpha$  frequencies of P3 are important for *Users 1 and 2* as well.

This sensor selection matches neurophysiological literature as in [38], but it adds certain features which are new to this. In fact, strong evidence of the importance of the sensor

TABLE 7: Features and RC values for the models calculated for the different users based on GMDH selection for fuzzy criteria scored data.

Features	RC
<i>User 1</i>	
$\{x_{38}\}$	67.96
$\{x_{38}, x_2\}$	80.12
$\{x_{38}, x_2, x_{27}\}$	80.77
$\{x_{38}, x_2, x_{27}, x_{62}\}$	<b>82.22</b>
<i>User 2</i>	
$\{x_2\}$	57.22
$\{x_2, x_{26}\}$	70.13
$\{x_2, x_{26}, x_{27}\}$	70.89
$\{x_2, x_{26}, x_{27}, x_{61}\}$	<b>71.54</b>
<i>User 3</i>	
$\{x_4\}$	49.58
$\{x_4, x_3\}$	51.70
$\{x_2, x_3, x_{49}\}$	<b>52.41</b>

positions C3 and C4 on the selection process has been found, but very little has been said about CP1, CP2, P3, or the adjacent channels. The difference on this research can be clearly motivated by the different way of constructing the data set as established in [39].

Also, the data set comprises a status which is not related to motor imagery, like it is imagining words beginning with the same random letter. This one could activate other areas of the brain and cause features not included in the previous research to appear as highly discriminant in our model.

**5.1. Processing Time Improvement.** The processing cost per feature added to the model has also been calculated for each subject.

- (1) At the preprocessing stage, and due to the calculations performed by the Welch periodogram PSD function, the time consumption is linear with the number of features and everyone's preprocessing cost is 1.04% of the total.
- (2) The neurofuzzy algorithm explained in this paper requires an increase of 9.21% of the processing time per feature during the model generation (learning and rule prune), which is very significant considering that six models are generated for each user.
- (3) A final 7.53% increase at the test stage for every feature added to the model is also required.

**5.2. Unified Model for the Three Users.** Table 8 shows the existence of a number of components which are selected by each individual user by all methods. For instance, being common to *User 1*, features  $x_2$  and  $x_{38}$  are always selected, while features  $x_2$  and  $x_{26}$  appear on all methods for *User 2* or  $x_3$  and  $x_4$  for *User 3*. These results have led the authors to

build a unified model across all users by selecting the features  $x_2$ ,  $x_3$ ,  $x_4$ ,  $x_{26}$ , and  $x_{38}$ . The accuracy achieved by this model is shown in Table 11.

As can be found, the accuracy is slightly lower than that in the user specific models, but the reduction is only a 3.43% and the results are only improved by those shown in EEG Mapping [37], which are calculated with a 5-second window (different from the 1 s window used in the rest of the methods).

A further investigation on this field should be carried out across a larger population to determine if a reduced set of common features across the users can be found as performed by Fazli et al. [40].

## 6. Conclusion

The most obvious finding to emerge from this study is a way of drastically reducing the number of features required on the processing of the BCI systems while maintaining and even improving their classification success rate. This approach, being a three-status paradigm where only two of them are motor imagery related, has not been commonly undertaken by the literature.

The results of this investigation show that a 96% reduction of the required number of features (from 96 to 4) for a selection method based on Fuzzy and GMDH algorithms can be achieved. This translates into important time saving in computational burden when the analysis of the time consumption is performed over this simplified model.

Moreover, the methodology proposed presents a native support to multiclass problems. Most of the research papers focus on reducing channels in two tasks motor imagery paradigms. Therefore, two-class classification algorithms are an excellent tool to address the problem yielding good results in terms of the calculation time and accuracy. However, when increasing the number of classes within the problem, feature selection methods based on algorithms such as CSF, FDA, SVM, and FC require a review of the entire system and the inclusions of decision trees. In addition, the calculations need to be repeated several times in two-class space combinations, increasing the processing time and power consumption before reaching an outcome.

In contrast, the use of S-dFasArt does not require any further tuning when increasing the number of classes and the processing time remains the same due to the fact that no new calculations are being required.

It has also been shown how the user and the features selected present an important correlation. As previous studies have reported, it has been found that the  $\alpha$  and  $\beta$  rhythms of the C3 and C4 channels present a big discriminant nature on the motor imagery tasks for all the studied users. Also, other  $\alpha$  and  $\beta$  rhythms appear to be relevant in this scenario, which includes a nonmotor imagery task. However, the generalization capability has shown to be low, as the subset of selected features appears to be very dependent on the subject performing the task.

Further experimental investigations are needed to estimate the smallest number of common features required for

TABLE 8: Results for the test session.

Selection method	Model	Success rate	Number	%
<i>User 1</i>				
None	$(x_1 \cdots x_{96})$	87.21	96	100.00
Statistic + Order	$(x_{38}, x_2)$	85.39	2	2.08
Statistic + GMDH	$(x_{38}, x_2, x_{31})$	87.64	3	3.13
Fuzzy + Order	$(x_{26}, x_{27}, x_{25}, x_{38}, x_2, x_3, x_{61}, x_{39}, x_{62})$	<b>89.95</b>	9	9.38
Fuzzy + GMDH	$(x_{38}, x_2, x_{27}, x_{62})$	89.50	4	4.17
<i>User 2</i>				
None	$(x_1 \cdots x_{96})$	82.26	96	100.00
Statistic + Order	$(x_{26}, x_2, x_1)$	81.80	3	3.13
Statistic + GMDH	$(x_2, x_{26}, x_5)$	81.57	3	3.13
Fuzzy + Order	$(x_{26}, x_2, x_1)$	81.80	3	3.13
Fuzzy + GMDH	$(x_2, x_{26}, x_{27}, x_{61})$	<b>82.49</b>	4	4.17
<i>User 3</i>				
None	$(x_1 \cdots x_{96})$	58.72	96	100.00
Statistic + Order	$(x_{39}, x_3, x_1, x_2, x_4, x_{31})$	57.57	6	6.25
Statistic + GMDH	$(x_4, x_3, x_{30})$	<b>59.40</b>	3	3.13
Fuzzy + Order	$(x_3, x_{74}, x_{39}, x_4, x_{73})$	52.52	5	5.21
Fuzzy + GMDH	$(x_4, x_3, x_{49})$	57.80	3	3.13
Average				
None		76.06	96.00	100
Statistic + Order		74.92	3.67	3.82
Statistic + GMDH		76.2	3.00	3.13
Fuzzy + Order		74.76	5.67	5.91
Fuzzy + GMDH		<b>76.6</b>	3.67	3.82

TABLE 9: Research classification success rate comparison.

Selection method	<i>User 1</i>	Feat	<i>User 2</i>	Feat	<i>User 3</i>	Feat	Av.
BCI Competition Winner	79.60	96	70.31	96	56.02	96	68.65
MDLA [41]	79.68	9	66.82	17	54.59	1	67.03
SVM with evolved spatial + frequency-selection filters [31]	78.14	32	71.33	16	59.07	40	69.58
EEG Mapping [37]	85.71	8	73.80	8	64.28	8	74.60
Statistic + GMDH	<b>87.64</b>	<b>3</b>	<b>81.57</b>	<b>3</b>	<b>59.40</b>	<b>3</b>	<b>76.20</b>

the exercise presented in this paper across a larger population. An important practical implication of this would be the manufacturing of low-cost headsets with a small number of sensors. Also, the processing should be quicker as the preprocessing stage and the classification algorithm would only perform calculations on a very small set of the sampled data. Therefore, the design of devices including a reduced number of sensors could be possible. This would allow the EEG systems to be more user friendly by drastically reducing the setup time. Also, more appealing headsets compared with the current cap system could be manufactured.

In summary, it has been demonstrated that the analysis of only a few frequency bands is required. This allows an important saving in computation time and power consumption as

well, which is beneficial when integrating the system, due to the fact that less processing power and memory resources are being required. The aforementioned benefits can be critical when designing applications where the available times to provide them with an output or the hardware platform are limited, for example, in applications for mobile devices.

As a consequence of the reduction in the hardware, the creation of an affordable mass market mobile system based on EEG would be possible.

### Conflict of Interests

The authors declare that there is no conflict of interests regarding the publication of this paper.

TABLE 10: Selected channels and frequencies for the Fuzzy + GMDH selection method.

	Frequency (Hz)											
	8	10	12	14	16	18	20	22	24	26	28	30
<i>User 1</i>												
C3	.	•	.	.	.	.	.	.	.	.	.	.
Cz	.	.	.	.	.	.	.	.	.	.	.	.
C4	.	.	•	.	.	.	.	.	.	.	.	.
CP1	.	•	.	.	.	.	.	.	.	.	.	.
CP2	.	.	.	.	.	.	.	.	.	.	.	.
P3	.	•	.	.	.	.	.	.	.	.	.	.
Pz	.	.	.	.	.	.	.	.	.	.	.	.
P4	.	.	.	.	.	.	.	.	.	.	.	.
<i>User 2</i>												
C3	.	•	.	.	.	.	.	.	.	.	.	.
Cz	.	.	.	.	.	.	.	.	.	.	.	.
C4	.	•	•	.	.	.	.	.	.	.	.	.
CP1	.	.	.	.	.	.	.	.	.	.	.	.
CP2	.	.	.	.	.	.	.	.	.	.	.	.
P3	•	.	.	.	.	.	.	.	.	.	.	.
Pz	.	.	.	.	.	.	.	.	.	.	.	.
P4	.	.	.	.	.	.	.	.	.	.	.	.
<i>User 3</i>												
C3	.	.	•	•	.	.	.	.	.	.	.	.
Cz	.	.	.	.	.	.	.	.	.	.	.	.
C4	.	.	.	.	.	.	.	.	.	.	.	.
CP1	.	.	.	.	.	.	.	.	.	.	.	.
CP2	•	.	.	.	.	.	.	.	.	.	.	.
P3	.	.	.	.	.	.	.	.	.	.	.	.
Pz	.	.	.	.	.	.	.	.	.	.	.	.
P4	.	.	.	.	.	.	.	.	.	.	.	.

TABLE 11: Research classification success rate comparison.

Selection method	<i>User 1</i>	Feat	<i>User 2</i>	Feat	<i>User 3</i>	Feat	Av.
BCI Competition Winner	79.60	96	70.31	96	56.02	96	68.65
MDLA [41]	79.68	9	66.82	17	54.59	1	67.03
SVM with evolved spatial + frequency-selection filters [31]	78.14	32	71.33	16	59.07	40	69.58
EEG Mapping [37]	85.71	8	73.80	8	64.28	8	74.60
Statistic + GMDH	<b>87.64</b>	<b>3</b>	<b>81.57</b>	<b>3</b>	<b>59.40</b>	<b>3</b>	<b>76.20</b>
Unified model	83.56	5	78.34	5	56.42	5	72.77













## References

- [1] W. Ting, Y. Guo-zheng, Y. Bang-hua, and S. Hong, "EEG feature extraction based on wavelet packet decomposition for brain computer interface," *Measurement*, vol. 41, no. 6, pp. 618–625, 2008.
- [2] M. A. Lebedev and M. A. L. Nicolelis, "Brain-machine interfaces: past, present and future," *Trends in Neurosciences*, vol. 29, no. 9, pp. 536–546, 2006.
- [3] J. L. Collinger, B. Wodlinger, J. E. Downey et al., "High-performance neuroprosthetic control by an individual with tetraplegia," *The Lancet*, vol. 381, no. 9866, pp. 557–564, 2013.
- [4] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, and T. M. Vaughan, "Brain-computer interfaces for communication and control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [5] A. Kostov and M. Polak, "Parallel man-machine training in development of EEG-based cursor control," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 203–205, 2000.
- [6] D. J. McFarland and J. R. Wolpaw, "Sensorimotor rhythm-based brain-computer interface (BCI): feature selection by regression improves performance," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 13, no. 3, pp. 372–379, 2005.

- [7] G. Rosas-Cholula, J. M. Ramírez-Cortes, V. Alarcón-Aquino, J. Martínez-Carballido, and P. Gómez-Gil, "On signal P-300 detection for BCI applications based on wavelet analysis and ICA preprocessing," in *Proceedings of the 7th IEEE Electronics, Robotics and Automotive Mechanics Conference (CERMA '10)*, pp. 360–365, Morelos, Mexico, October 2010.
- [8] Y. Li, J. Pan, F. Wang, and Z. Yu, "A hybrid BCI system combining P300 and SSVEP and its application to wheelchair control," *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 11, pp. 3156–3166, 2013.
- [9] R. C. Panicker, S. Puthusserypady, and Y. Sun, "An asynchronous P300 BCI with SSVEP-based control state detection," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 6, pp. 1781–1788, 2011.
- [10] E. Yin, Z. Zhou, J. Jiang, F. Chen, Y. Liu, and D. Hu, "A novel hybrid BCI speller based on the incorporation of SSVEP into the P300 paradigm," *Journal of Neural Engineering*, vol. 10, no. 2, Article ID 026012, 2013.
- [11] D. J. McFarland, L. M. McCane, S. V. David, and J. R. Wolpaw, "Spatial filter selection for EEG-based communication," *Electroencephalography and Clinical Neurophysiology*, vol. 103, no. 3, pp. 386–394, 1997.
- [12] A. Bashashati, M. Fatourehchi, R. K. Ward, and G. E. Birch, "A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals," *Journal of Neural Engineering*, vol. 4, no. 2, pp. R32–R57, 2007.
- [13] E. A. Mousavi, J. J. Maller, P. B. Fitzgerald, and B. J. Lithgow, "Wavelet Common Spatial Pattern in asynchronous offline brain computer interfaces," *Biomedical Signal Processing and Control*, vol. 6, no. 2, pp. 121–128, 2011.
- [14] J.-M. Cano-Izquierdo, M. Almonacid, M. Pinzolas, and J. Ibarrola, "dFasArt: dynamic neural processing in FasArt model," *Neural Networks*, vol. 22, no. 4, pp. 479–487, 2009.
- [15] J.-M. Cano-Izquierdo, M. Almonacid, and J. J. Ibarrola, "Applying neuro-fuzzy model dFasArt in control systems," *Engineering Applications of Artificial Intelligence*, vol. 23, no. 7, pp. 1053–1063, 2010.
- [16] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, "A review of classification algorithms for EEG-based brain-computer interfaces," *Journal of Neural Engineering*, vol. 4, no. 2, pp. R1–R13, 2007.
- [17] J. Yang, H. Singh, E. L. Hines et al., "Channel selection and classification of electroencephalogram signals: an artificial neural network and genetic algorithm-based approach," *Artificial Intelligence in Medicine*, vol. 55, no. 2, pp. 117–126, 2012.
- [18] W.-K. Tam, K.-Y. Tong, F. Meng, and S. Gao, "A minimal set of electrodes for motor imagery BCI to control an assistive device in chronic stroke subjects: a multi-session study," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 19, no. 6, pp. 617–627, 2011.
- [19] Biosemi, 2015, <http://www.biosemi.com/faq/prices.htm>.
- [20] M. Schroder, M. Bogdan, T. Hinterberger, and N. Birbaumer, "Automated EEG feature selection for brain computer interfaces," in *Proceedings of the 1st International IEEE EMBS Conference on Neural Engineering*, pp. 626–629, Capri Island, Italy, 2003.
- [21] D. Garrett, D. A. Peterson, C. W. Anderson, and M. H. Thaut, "Comparison of linear, nonlinear, and feature selection methods for EEG signal classification," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 141–144, 2003.
- [22] D. Flotzinger, M. Pregenzer, and G. Pfurtscheller, "Feature selection with distinction sensitive learning vector quantisation and genetic algorithms," in *Proceedings of the IEEE World Congress on Computational Intelligence*, pp. 3448–3451, Shanghai, China, 1994.
- [23] M. Deriche and A. Al-Ani, "A new algorithm for EEG feature selection using mutual information," in *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing*, vol. 2, pp. 1057–1060, Shanghai, China, May 2001.
- [24] T. N. Lal, M. Schröder, T. Hinterberger et al., "Support vector channel selection in BCI," *IEEE Transactions on Biomedical Engineering*, vol. 51, no. 6, pp. 1003–1010, 2004.
- [25] Y. Wang, S. Gao, and X. Gao, "Common spatial pattern method for channel selection in motor imagery based brain-computer interface," in *Proceedings of the 27th Annual International Conference of the Engineering in Medicine and Biology Society (EMBS '05)*, pp. 5392–5395, IEEE, Shanghai, China, September 2005.
- [26] M. Arvaneh, C. Guan, K. K. Ang, and C. Quek, "Optimizing the channel selection and classification accuracy in EEG-based BCI," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 6, pp. 1865–1873, 2011.
- [27] L. He, Y. Hu, Y. Li, and D. Li, "Channel selection by Rayleigh coefficient maximization based genetic algorithm for classifying single-trial motor imagery EEG," *Neurocomputing*, vol. 121, pp. 423–433, 2013.
- [28] M. Arvaneh, C. Guan, K. K. Ang, and C. Quek, "Robust EEG channel selection across sessions in brain-computer interface involving stroke patients," in *Proceedings of the Annual International Joint Conference on Neural Networks (IJCNN '12)*, pp. 1–6, IEEE, June 2012.
- [29] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, "Filter Bank Common Spatial Pattern (FBCSP) in brain-computer interface," in *Proceedings of the International Joint Conference on Neural Networks (IJCNN '08)*, pp. 2390–2397, IEEE, June 2008.
- [30] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, "Mutual information-based selection of optimal spatial-temporal patterns for single-trial EEG-based BCIs," *Pattern Recognition*, vol. 45, no. 6, pp. 2137–2144, 2012.
- [31] R. Aler, I. M. Galván, and J. Valls, "Applying evolution strategies to preprocessing EEG signals for brain-computer interfaces," *Information Sciences*, vol. 215, pp. 53–66, 2012.
- [32] J.-M. Cano-Izquierdo, J. Ibarrola, and M. Almonacid, "Improving motor imagery classification with a new BCI design using neuro-fuzzy S-dFasArt," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 20, no. 1, pp. 2–7, 2012.
- [33] Berlin Brain-Computer Interface (BCI), *BCI Competition III*, 2004.
- [34] J. D. R. Millán, "On the need for on-line learning in brain-computer interfaces," in *Proceedings of the IEEE International Joint Conference on Neural Networks*, vol. 4, pp. 2877–2882, July 2004.
- [35] P. A. Devijver and J. Kittler, *Pattern Recognition: A Statistical Approach*, Prentice Hall, 1982.
- [36] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling," *IEEE Transactions on Fuzzy Systems*, vol. 1, no. 1, pp. 7–31, 1993.
- [37] A. Úbeda, E. Iáñez, J. M. Azorín, J. M. Sabater, and E. Fernández, "Classification method for BCIs based on the correlation of EEG maps," *Neurocomputing*, vol. 114, pp. 98–106, 2013.

- [38] M. Pregenzer and G. Pfurtscheller, "Frequency component selection for an EEG-based brain to computer interface," *IEEE Transactions on Rehabilitation Engineering*, vol. 7, no. 4, pp. 413–419, 1999.
- [39] J. D. R. Millán, M. Franzé, J. Mouriño, F. Cincotti, and F. Babiloni, "Relevant EEG features for the classification of spontaneous motor-related tasks," *Biological Cybernetics*, vol. 86, no. 2, pp. 89–95, 2002.
- [40] S. Fazli, F. Popescu, M. Danóczy, B. Blankertz, K.-R. Müller, and C. Grozea, "Subject-independent mental state classification in single trials," *Neural Networks*, vol. 22, no. 9, pp. 1305–1312, 2009.
- [41] M. S. Mahanta, A. S. Aghaei, and K. N. Plataniotis, "A Bayes optimal matrix-variate LDA for extraction of spatio-spectral features from EEG signals," in *Proceedings of the 34th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS '12)*, pp. 3955–3958, September 2012.







**2017 journal performance data for: EXPERT SYSTEMS WITH APPLICATIONS**

ISSN: 0957-4174

eISSN: 1873-6793

PERGAMON-ELSEVIER SCIENCE LTD

THE BOULEVARD, LANGFORD LANE, KIDLINGTON, OXFORD OX5 1GB, ENGLAND

USA

**TITLES**

ISO: Expert Syst. Appl.

JCR Abbrev: EXPERT SYST APPL

**LANGUAGES**

English

**CATEGORIES**



COMPUTER SCIENCE, ARTIFICIAL INTELLIGENCE - SCIE

ENGINEERING, ELECTRICAL &amp; ELECTRONIC - SCIE

OPERATIONS RESEARCH &amp; MANAGEMENT SCIENCE - SCIE

**PUBLICATION FREQUENCY**

24 issues/year

**2017 Journal Impact Factor & percentile rank in category for: EXPERT SYSTEMS WITH APPLICATIONS**
**3,768**  
 2017 Journal Impact Factor

**2017 JIF citation distribution for: EXPERT SYSTEMS WITH APPLICATIONS**


## Journal Impact Factor Calculation

$$\text{2017 Journal Impact Factor} = \frac{5,355}{1,421} = 3.768$$

How is Journal Impact Factor Calculated?

$$\text{JIF} = \frac{\text{Citations in 2017 to items published in 2015 (3433) + 2016 (1922)}{\text{Number of citable items in 2015 (791) + 2016 (630)}} = \frac{5,355}{1,421}$$

## Journal Impact Factor contributing items

[Show all](#)[Citable items in 2016 and 2015 \(1,421\).](#)[Citations in 2017 \(5,355\).](#)

TITLE	CITATIONS COUNTED TOWARDS JIF
<a href="#">Fuzzy multiple criteria decision-making techniques and applications - Two decades review from 1994 to 2014</a>	71
By: Mardani, Abbas; Jusoh, Ahmad; Zavadskas, Edmundas Kazimieras Volume: 42 Page: 4126-4148 Accession number: WOS:000356904100028 Document Type:Review	
<a href="#">Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions</a>	48
By: Sharma, Rajeev; Pachori, Ram Bilas Volume: 42 Page: 1106-1117 Accession number: WOS:000345734700013 Document Type:Article	
<a href="#">CloudID: Trustworthy cloud-based and cross-enterprise biometric identification</a>	34
By: Haghighat, Mohammad; Zonouz, Saman; Abdel-Mottaleb, Mohamed Volume: 42 Page: 7905-7916 Accession number: WOS:000360772500052 Document Type:Article	
<a href="#">Multi-objective grey wolf optimizer: A novel algorithm for multi-criterion optimization</a>	29
By: Mirjalili, Seyedali; Saremi, Shahrzad; Mirjalili, Seyed Mohammad; Coelho, Leandro dos S. Volume: 47 Page: 106-119 Accession number: WOS:000368967900010 Document Type:Article	
<a href="#">Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques</a>	24
By: Patel, Jigar; Shah, Sahil; Thakkar, Priyank; Kotecha, K. Volume: 42 Page: 259-268 Accession number: WOS:000344034300022 Document Type:Article	

## Key Indicators 2017



<b>Year</b>	2017	<b>5 Year Impact Factor</b>	3,711	<b>Cited Half-Life</b>	6,1	<b>Article Influence Score</b>	0,763	<b>Average JIF Percentile</b>	86,779
<b>Total Cites</b>	33,177	<b>Immediacy Index</b>	0,876	<b>Citing Half-Life</b>	7,6	<b>% Articles in Citable Items</b>	97,75		
<b>Journal Impact Factor</b>	3,768	<b>Citable Items</b>	622	<b>Eigenfactor Score</b>	0,04400	<b>Normalized Eigenfactor</b>	5,18200		
<b>Impact Factor Without Journal Self Cites</b>	3,331								

## Contributions by country/region




country	count
1. CHINA MAINLAND	338
2. Spain	261
3. USA	242
4. Brazil	146
5. India	143
6. South Korea	129
7. England	127
8. Turkey	96
9. Iran	91
10. Canada	88

## Contributions by organizations



organization	count
1. INDIAN INSTITUTE OF TECHNOLOGY (IIT)	51
2. COMPLUTENSE UNIVERSITY OF MADRID	25
- STATE UNIVERSITY SYSTEM OF FLORIDA	25
4. UNIVERSITI MALAYA	24
- ISLAMIC AZAD UNIVERSITY	24
6. CENTRE NATIONAL DE LA RECHERCHE SCIENTIFIQUE (CNRS)	23
7. UNIVERSIDADE DE SAO PAULO	22
8. HONG KONG POLYTECHNIC UNIVERSITY	20
9. YONSEI UNIVERSITY	19
- HUAZHONG UNIVERSITY OF SCIENCE & TECHNOLOGY	19



# Are low cost Brain Computer Interface headsets ready for motor imagery applications?



Juan-Antonio Martinez-Leon\*, Jose-Manuel Cano-Izquierdo, Julio Ibarrola

Department of Systems Engineering and Automatic Control, Technical University of Cartagena, Campus Muralla del Mar, C/ Dr. Fleming S/N, 30202 Cartagena, Spain

## ARTICLE INFO

### Keywords:

Consumer EEG  
BCI Competition  
Emotiv EPOC  
Motor imagery  
Application performance comparison

## ABSTRACT

Low cost electroencephalography (EEG) headset devices for brain data capturing are fast becoming a key instrument on Brain Computer Interface (BCI) applications. In spite of being a controller device initially developed for gaming, the research community has adopted them as a key element to gather EEG data. However, there have been little discussion about their performance when being compared with professional and research EEG headsets.

This paper provides an assessment of one of these devices, the Emotiv EPOC, on a motor imagery problem. As a benchmark, the data and results presented for the Data Set V of the BCI Competition III have been used, which were recorded with a professional Biosemi Active 2 EEG headset. From the perspective of a final working application, it is shown that the performance of this headset is comparable to that found in professional devices when using the same number of sensors and sensor positions for a three status motor imagery cognitive process. This finding implies an increase on the number of EEG headsets the researchers and manufacturers of BCI systems applied to motor imagery problems can integrate and a reduction of their cost.

As part of this paper the Emotiv EPOC recorded raw and pre-processed datasets are published to allow further improvements and comparisons.

© 2015 Elsevier Ltd. All rights reserved.

## 1. Introduction

The EEG headsets are the most relevant brain signal capturing devices in the scientific environment, accounting for over 80% of the publications related to BCI systems (AlZu'bi, Al-Zubi, & Al-Nuaimy, 2011). Different manufacturers and headset models used by different researchers, apart from information being recorded from different subjects, have always imposed a challenge when comparing the achievements presented. Moreover, low cost EEG headsets are fast becoming a key instrument in research applications despite of being originally designed for video gaming and entertaining. Therefore, the need of a comparison between the precision and performance of research and low cost headset based BCI systems has become a major area of interest.

The purpose of this paper is to evaluate the accuracy attained by a low cost headset using data recorded by a professional device as a benchmark, both from the perspective of a complete BCI system.

Thus, the performance of the low cost Emotiv EPOC headset as an EEG signal acquisition device is compared with the standard BCI Competition III Data Set V benchmark problem.

The BCI Competition contest was organized with the aim of promoting the BCI technologies, providing with common data sets to evaluate the accuracy of different pre-processing and classification algorithms and methodologies. Several calls of this contest were organized where different classic BCI problems were outlined. As part of the BCI Competition III the "Data Set V: Multiclass Problem, Continuous EEG" was provided (Blankertz et al., 2006). The problem consisted of properly classifying three mental tasks: left hand movement, right hand movement and generation of words beginning with the same random letter. The availability of this standardized dataset in particular has allowed the research community to create a considerable amount of literature after the BCI contest (Aler, Galván, & Valls, 2009; 2010; 2012; Bueno & Bastos-Filho, 2015; Galán, Oliva, & Guardia, 2007; Ghosh, Mazumder, Bhattacharyya, Tibarewala, & Hayashibe, 2015; Lin & Hsieh, 2009; Martinez-Leon, Cano-Izquierdo, & Ibarrola, 2015; Moon, Bawane, & Hazare, 2015; Sun & Zhang, 2006; Sun, Zhang, & Lu, 2008).

Likewise, the demand for easy-to-use, low cost, wireless EEG systems designed for non-research applications such as video games and

\* Corresponding author. Tel.: +34 968338921; fax: +34 968325355.

E-mail addresses: [jml16@alu.upct.es](mailto:jml16@alu.upct.es) (J.-A. Martinez-Leon), [josem.cano@upct.es](mailto:josem.cano@upct.es) (J.-M. Cano-Izquierdo), [juliojose.ibarrola@upct.es](mailto:juliojose.ibarrola@upct.es) (J. Ibarrola).

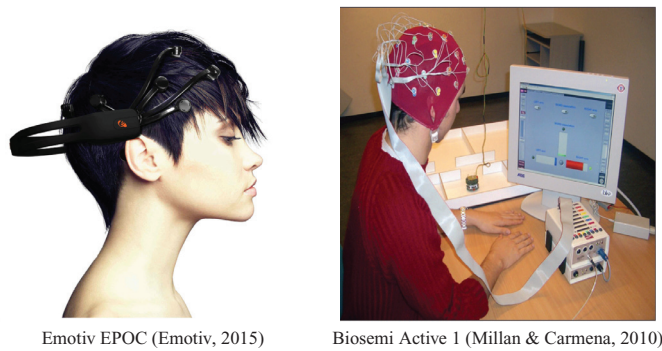


Fig. 1. Headset physical features comparison (Millan & Carmena, 2010).

entertaining (Van-de Laar, Gurkok, Plass-Oude Bos, Poel, & Nijholt, 2013; Van-Vliet et al., 2012; Vourvopoulos, Liarokapis, & Petridis, 2012), has paved the way for the creation of new neuroscience applications. Brands like (Neurosky, 2015) or (Emotiv, 2015) have created user-friendly headsets aimed at this public, while because of their research use, have released application program interfaces (API) allowing access to the raw brain signals captured. Due to having the highest number of sensors integrated (14) and its usability and setup time, the Emotiv EPOC is an appealing option for researchers as Fig. 1 shows on the left side.

Also, several studies have documented that the Emotiv EPOC headset shows a good performance when detecting mental activity with the aim of identifying several mental actions (Taylor & Schmidt, 2012). Moreover, a number of investigators have reported an increasing number of applications in different BCI research areas. For instance, Khushaba et al. (2012); (2013) use it to study the mental tasks associated to the choice decision making. In Badcock et al. (2013), the Emotiv EPOC headset is evaluated for the auditory event-related potential capturing, leading to the positive outcome of being considered a valid alternative to undertake the issue. Analogous outcome is presented by Clemente, Rodriguez, Rey, and Alcañiz (2014), where the brain activations elicited by the presence in a virtual environment are analyzed. Other researchers have also included it in the implementation of an interface with assistive technologies (Lievesley, Wozen-croft, & Ewins, 2011), in the movement of orthotics for stroke patients (Fok et al., 2011), for robot control (Esfahani & Sundararajan, 2011), or in vehicle (Cernea et al., 2011) or tractor driving (Gómez-Gil, San-José-González, Nicolás-Alonso, & Alonso-García, 2011), where the accuracy of the system is compared with different guiding methods such as GPS or manual.

Debener, Minow, Emkes, Gandras, and Vos (2012) replace the Emotiv EPOC sensors by sintered Ag/Cl electrodes and a cap is also integrated to redistribute their position. The system is then used to capture EEG data from static users in an isolated environment as well as users in an external one. It is shown that a mobile BCI system based on a low-cost EEG headset is possible. A similar hybrid system is used in Stopczynski et al. (2013), where an acquisition and analysis low cost system allowing quality-enough data to undertake multiple classical neuroscience applications including Brain Computer Interfaces, analysis of high-level brain activity and neurofeedback, is proposed. The same system has been used once again in De-Vos, Gandras, and Debener (2013) and the possibility of taking quality enough data from walking subjects is demonstrated.

Duvinage et al. (2013) carried out a comparison between a medical system and one using the Emotiv EPOC headset. The outcome of the previous work shows a lower accuracy of the Emotiv EPOC when compared with a medical system in classification problems, although Emotiv EPOC is still considered by the authors a valid alternative when restricted to non-critical applications. Bobrov, Frolov, Cantor, Fedulova, and Zhavoronkov (2011) analyzed mental tasks related of

image classification: think about a house, a face and relax. The results attained by both an Emotiv EPOC and an ActiCap are compared as alternatives for data capture.

More recent literature highlights the importance of BCI systems based on the Emotiv EPOC headset for the research community in different applications. Kumari and Vaish (2015) present a work where the headset has been used to build an authentication system based on visual stimuli while Dkhil, Neji, Wali, and Alimi (2015) build a system to detect drowsiness in drivers traveling long distances. Also, with a more medical focus, McMahan, Parberry, and Parsons (2015) integrate this same EEG headset to assess the cognitive processes happening in the brain of people playing video games, finding power changes on the beta and gamma bands.

From the different works presented above, it can be stated an increasing interest of using low cost EEG systems, like the Emotiv EPOC. For this reason, it is of an interest to apply these low cost systems to end to end problems and compare them with standard benchmarks. Several researchers demonstrate that the quality of the data recorded by using Emotiv EPOC cannot compete with the quality of the data recorded using professional devices, moreover when it comes to evaluate raw signal parameters like signal to noise ratio of the artifacts. However, Emotiv appears to be a viable alternative when the focus changes to application development or to provide with useful data to test classification algorithms.

In AlZu'bi et al. (2011) the use of the Emotiv headset is applied to the Dataset I of the BCI Competition IV (Tangemann et al., 2012). In this study, similar accuracy levels are achieved applying the same methods in both the contest data and the data set recorded from different users wearing an Emotiv headset.

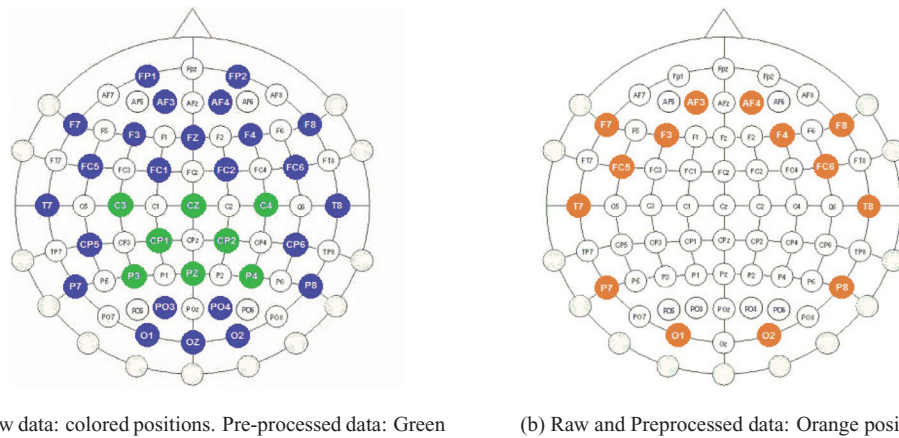
In these scenarios, factors like the signal preprocessing or the classification methodology can reduce the relevance of the quality of the raw data, as they have an important effect in the accuracy of the system.

The Emotiv EPOC datasets used for the BCI system comparison presented in this paper have been recorded based on the multiclass motor imagery paradigm using continuous EEG. Obviously, the signals are recorded from different subjects to those of the BCI Competition Data Set V and it can be seen that the distribution of the sensors is not the same as the one on the BCI Competition either. These restrictions imply that the comparison between both datasets needs to be done at the application level, for instance comparing the accuracy of both systems when completing the same defined task: predict a mental action.

The BCI system built in this research is based on a S-dFasArt classification methodology (Cano-Izquierdo, Ibarrola, & Almonacid, 2012). The ARTMAP architecture model facilitates the interpretability of the data, adjusting the size of the categories in an adaptive way according to the learning data. This feature makes this technology very powerful in scenarios with very noisy signals. On the other hand, the calculations required to produce a prediction are heavy. Approaches like the one presented in Úbeda, Iáñez, Azorín, Sabater, and Fernández (2013) can present faster responses, although the classification success rate achieved is lower. Therefore, the authors have already undertaken the task of reducing the calculations by reducing the size of the input data as shown in Martinez-Leon et al. (2015).

Section 2 includes a description of the datasets used. For the Emotiv data, we have tried to create the same conditions and use the same methods as those used to create the Data Set V. Likewise, a description of the pre-processing stage and the Neuro-Fuzzy classification method used in both data sets is also provided in Section 3. Section 4 details the results of the calculations made to the different dataset configurations, which are discussed on Section 5. Finally, Section 6 summarizes the main conclusions obtained. The recorded datasets containing the raw signals captured with Emotiv EPOC and pre-processed datasets calculated to perform the calculations presented on this paper are made public for other researchers as part





(a) Raw data: colored positions. Pre-processed data: Green

(b) Raw and Preprocessed data: Orange positions.

**Fig. 2.** Sensor positions for the BCI Competition (left) and Emotiv EPOC headset channels (right). (For interpretation of the references to color in this figure, the reader is referred to the web version of this article).

of this paper. The format of the data is further explained in the [Appendix A](#).

## 2. Material and methods

Data from six different subjects is being used in this paper: Data Set V recording from 3 users from the BCI Competition III contest; and brain signal captured from other 3 subjects performing the same actions in an analogous environment as defined on the BCI Competition Data Set V, but wearing an Emotiv EPOC headset.

We assume that maintaining the signal acquisition process, the signal processing and the classification method analogous, any difference in the performance of the system must be mainly related to the difference in the quality of the underlying captured brain signal data.

### 2.1. BCI Competition III Data Set V

The Data Set V “Mental Imagery, Multiclass” was provided by the IDIAP Research Institute of Switzerland in the framework of the BCI Competition III ([Blankertz et al., 2006](#)) organized in 2004 by the Berlin Brain–Computer Interface area of the Berlin Institute of Technology. The signals were captured by using a Biosemi Active Two headset including 32-channels, whose pretax cost is around 25,000\$ ([Biosemi, 2015](#)). The Data Set V provides raw data from the 32 sensors and preprocessed data from those in positions C3, Cz, C4, CP1, CP2, P3, Pz, and P4 (International 10–20 locations).

The brain signals were recorded from three healthy users sat on a normal chair whom have been presented three different statuses:

1. Think about continuously moving the left hand (class 2, “L”)
2. Think about continuously moving the right hand (class 3, “R”)
3. Think about words starting with the same defined character (class 7, “W”)

The recordings were completed during the same day and organized as four sessions of 4 min devoted to the experiment in which each user was asked to perform during 15 s, in random order, one out of the three different tasks presented above. The subjects were allowed to relax between 5 and 10 min between sessions. The data sampling rate was 512 Hz, the signals were acquired at full DC and no artifact or correction was employed. For later sections of this paper, these users have been called Subject 1, Subject 2 and Subject 3.

Three sessions per user were provided as training sessions whereas the last one was the test session the BCI Competition organizers used to evaluate the accuracy of the different approaches to this benchmark.

One of the BCI Competition rules for this Data Set was limiting the data or “memory” of the system to the last second of recorded data. Also, a prediction had to be produced every 0.5 s. Applying these constraints imply to use a maximum window size of 512 samples from each of the included sensors in the calculations previous to a prediction.

#### 2.1.1. BCI Competition III Data Set V pre-processed datasets

Data Set V is composed by two different datasets. First, raw data from 32 channels of the Biosemi headset are provided (green and blue positions in [Fig. 2a](#)). Second, preprocessed data from only 8 channels out of the 32 are also given (C3, Cz, C4, CP1, CP2, P3, Pz, and P4 – green only positions).

According to the BCI Competition III rules for this experiment the raw data is, in the first place, spatially filtered by means of a Surface Laplacian (SL). After that, the Power Spectral Density (PSD) is calculated using a 1 s window of the available data. Because of the resolution of the PSD calculation is 2 Hz in the frequency band between 8 and 30 Hz a new value of the PSD is calculated with a frequency of 16 Hz. This way, during the half a second available to make a prediction, 8 vectors per sensor are generated.

Also, each vector is formed by 12 elements, which is the number of frequency bands from 8 to 30 Hz when using a bandwidth of 2 Hz, by the number of sensors included (8 in the preprocessed datasets). Therefore, a preprocessed data vector is composed by 96 elements. Moreover, due to the restriction of making a prediction every half a second, only 8 vectors can be considered. As a result, it can be concluded that there are 8 vectors of 96 elements (8 sensors \* 12 frequencies) available to provide with a prediction, which reflect the recorded information by the sensors during the last second.

#### 2.2. Emotiv

The Emotiv EPOC headset is a wireless EEG headset which includes 14 sensors placed in the positions AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 of the standard 10–20 international EEG positioning system as shown in [Fig. 2b](#). These sensors are attached to a plastic arms and only require to be moistened with a saline solution to make the system usable. This feature allows to complete the headset setup before an experiment in a few minutes. The headset communicates with a computer wirelessly via Bluetooth on the 2.4 GHz band using a proprietary USB dongle which is provided. The internal sampling frequency is 2048 Hz which gets down-sampled to 128 Hz, which is the rate delivered to any external application.

Also, the cost of this headset reaches a maximum of 700\$ when purchasing the research license, which allows access to the raw EEG data ([Emotiv, 2015](#)).



**Fig. 3.** Subject repeating the BCI Competition experiment wearing an Emotiv EPOC headset.

The design of the experiment was based on the BCI Competition III Set V rules with the aim of producing a comparable set of data. Therefore, the Emotiv Software Development Kit (SDK) and Matlab have been used to develop an application which creates the scenario, captures the data, processes it and delivers it in the same format as the BCI Competition datasets.

To carry out the experiment three subjects were chosen. They sat on a normal chair, with relaxed arms resting on their legs in front of a computer screen (Fig. 3). After that, they completed four sessions each with a rest period between sessions between 5 and 10 min, three of which are used to generate and train the classifier, while the last is used during the test stage. Each session lasted 4 min and consisted of three randomly presented tasks every 15 s. In order to produce comparable datasets, the users were asked to perform the same three tasks defined on the BCI Competition contest: think about continuously moving their left hand, think about continuously moving their right hand and think about words starting with a randomly defined character with no feedback. All subjects recorded their sessions during 1 day. For later sections of this paper, these users are referenced as Subject 4, Subject 5 and Subject 6.

When describing the different users is worth considering that Subject 4 has previous experience in the use of the Emotiv EPOC headset. However, the other two (Subjects 5 and 6) lacked of any experience with any BCI system.

Also, an area where significant differences exist is the data sampling. As previously explained, and opposite to the Biosemi system whose sampling frequency is 512 Hz, the Emotiv EPOC headset only provides EEG raw data at a rate of 128 Hz. To maintain the number of vectors available and comply with the restrictions presented in Section 2.1, the size of the windows has been reduced to 128 samples. As a consequence, there are 8 vectors of 168 elements (14 sensors by 12 frequencies) available to provide a prediction each half a second.

### 2.2.1. Emotiv pre-processed datasets

The preprocessing methodology applied is analogous to that proposed in the BCI Competition. A SL has been applied to spatially filter the raw data and the calculation of the PSD is performed to obtain the features vector. The number and frequency bands have also been preserved (12 frequency bands of 2 Hz between 2 and 30 Hz). The PSD has been calculated 16 times per second and, according to the prediction frequency rule, there are 8 vectors of dimension 168 (14 sensors by 12 frequency bands).

## 3. Theory

### 3.1. Data pre-processing

The purpose of the pre-processing stage is to increase the signal-to-noise ratio of the recorded control EEG signal. The EEG potentials

measured on the scalp have very low amplitude. For this reason, any interference coming from sources such as eye movement, eye-blink, any muscular movement, teeth clash or the heart rhythm deeply affect the quality of the signal measured. This can prevent the decoding system to recognize the control signal recorded properly.

As explained in the previous section, the Surface Laplacian (SL) computation (McFarland, McCane, David, & Wolpaw, 1997) was used by the BCI Competition III Data Set V providers and it is used again by us in this research to process the Emotiv EPOC data. This method acts as a high-pass spatial filter, returning almost reference-free signals. The Laplacian Surface method emphasizes the activity of the signals surrounding the channel of interest. The value of the SL at each electrode location is calculated as an estimation of the radial current density at that location. This method includes the calculation of the second order spatial derivatives of the instantaneous spatial voltage distribution. However, for our research the calculation will be based on a finite difference method which approximates the second derivative by subtracting a weighted mean of the surrounding potentials of the channel of interest.

The data obtained from this method has been computed by estimating the Power Spectral Density (PSD) for the frequency band between 8 and 30 Hz with a resolution of 2 Hz. The data have been divided in windows of 1 s with an advance rate based on the sampling frequency divided by 16, which defines an overlapping of 93.75% between windows. These have been individually processed by dividing the window in 8 segments with 50% overlapping, with a Hanning window of the same length applied to each segment. The PSD calculation is based on the Welch periodogram algorithm.

### 3.2. Classification

A quantitative approach has been employed to evaluate the quality of the data captured by the Emotiv EPOC headset. It was decided that the best method to adopt for this investigation was to assess the accuracy of the output provided by a common classification algorithm. This calculation is performed using an architecture based on dFasArt models (Cano-Izquierdo, Almonacid, Pinzolas, & Ibarrola, 2009). These are neuro fuzzy models which use Neural Networks based rules to create a structure which can be interpreted as a Fuzzy Logic System. The architecture used for the recognition process is shown in Fig. 4 (Cano-Izquierdo et al., 2012).

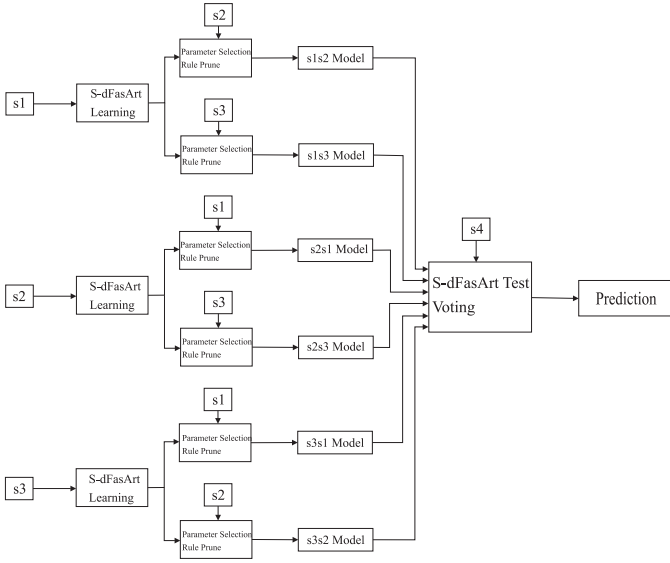
This methodology is based on grouping the training sessions in combinations of two. During the classifier training, the three first recorded sessions are used. Due to there are three different sessions for the learning stage, six possible combinations can be evaluated and six different models are finally available to complete the overall test. For each pair or different sessions, one of them is used as a learning session of a S-dFasArt module whereas the other is used for parameter adjustment. After this initial phase an intermediate output is provided. On subsequent stages, the second session is also used to perform a rule prune in the S-dFasArt module.

The final test phase makes use of the fourth available session. Each one of the six models previously created contributes with one prediction for each input vector. Because, according to the BCI Competition rules, an outcome needs to be produced every half a second and the data is split in vectors of information at a rate of 16 Hz, only 8 vectors can be used.

Therefore, there are 8 vectors and 6 models, which yield 48 predictions every 0.5 s. After that, a voting mechanism between the different predictions is used in order to choose the most frequent one.

## 4. Results

To assess the quality of the data recorded by using the Emotiv EPOC headset, three different criteria are evaluated:



**Fig. 4.** FasArt system description building blocks. Each available training session is used for learning and combined with all the other learning sessions for parameter adjustment and rule prune. This creates intermediate models which are finally combined on a S-dFasArt test module, where a voting strategy is implemented to choose the winning class.

1. A new category called “Motor”, including the motor categories of the experiment “L” y “R” has been specified. Then, the average motor accuracy ( $M_A$ ) has been defined as the number of times where the prediction is right for motor tasks ( $C_M$ ) and no-motor ( $C_W$ ) divided by the total number of vectors in the test session ( $V_T$ ).

$$M_A = \frac{C_M + C_W}{V_T} \quad (1)$$

2. Right Success ( $S_R$ ), Left Success ( $S_L$ ) and Word Success ( $S_W$ ) rates have been calculated dividing the number of times the system properly predicted a defined status ( $C_X$ ) by the number of each category vectors available in the test data set ( $V_X$ ). As an example:

$$S_R = \frac{C_R}{V_R} \quad (2)$$

3. Confusion matrixes. Present an error matrix where the number of times a pattern is mistaken by a different one is shown. Each column of the matrix presents the instances in a predicted class while the rows represent the instances in an actual class. One of the advantages of this tool is the visibility given to confusions between two classes.

The calculations above have been repeated across three different datasets:

1. BCI Competition Data Set V pre-processed data. Brain signal feature information belonging to the channels C3, Cz, C4, CP1, CP2, P3, Pz and P4, which are placed on the central-parietal area of the brain is used.
2. BCI Competition Data Set V pre-processed data including only the positions covered by the Emotiv EPOC headset (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4).
3. Emotiv EPOC data. Pre-processed brain signals from the 14 channels available are analyzed (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4).

#### 4.1. BCI Competition III Data Set V pre-processed data

In the first part of the calculations, the precision level achieved using BCI Competition preprocessed data is assessed. Hence, the

**Table 1**

Accuracy levels achieved using the BCI Competition III Data Set V shown as %.

	Success Rate				
	Global	Motor	Right	Left	Word
Subject 1	87.67	92.47	78.91	92.31	90.56
Subject 2	82.26	88.02	81.25	77.78	85.71
Subject 3	58.72	75.23	73.97	24.00	80.00

**Table 2**

BCI Competition III Data Set V confusion matrix values

	Predicting Left			Predicting Right		Predicting Word	
	Real Left	Real Right	Real Word	Real Left	Real Right	Real Word	Real Word
Subject 1							
Real Left	120	16	10	5	101	7	5
Real Right							
Real Word							
Subject 2							
Real Left	84	4	16	21	117	10	3
Real Right							
Real Word							
Subject 3							
Real Left	36	13	14	59	108	14	55
Real Right							
Real Word							

**Table 3**

Accuracy level achieved using the Emotiv EPOC channel positions extracted from the BCI Competition Data Set V shown as %.

	Success Rate				
	Global	Motor	Right	Left	Word
Subject 1	63.40	83.19	93.57	19.72	73.94
Subject 2	59.07	68.35	46.25	25.83	90.21
Subject 3	42.23	59.45	32.72	26.58	67.95

baseline for later comparisons with the other two approaches is established. Fig. 2a shows in green the location of the sensors included in the preprocessed BCI Competition Set V dataset, which is restricted to the channel positions C3, Cz, C4, CP1, CP2, P3, Pz, and P4. Table 1 presents the accuracy levels achieved.

Table 2 shows a marked relationship between the Predicting Left motor task and the overall success rate. For Subject 1, the one achieving the highest score, the algorithm is capable classifying 120 out of 130 occurrences (92.31%). In contrast, Subject 2 only achieves 84 out of 108 (77.78%) and Subject 3 shows a drop on the success rate down to 36 out of 150 (24%). On the other two statuses (Predicting Right and Word) the confusion matrix offers more homogeneous values although better performance for Predicting Word can be clearly found for all subjects. In fact, Predicting Word is the status most successfully predicted by the classification method.

#### 4.2. Data Set V Emotiv channels

Due to the Data Set of the BCI Competition III provides raw data for all the channel positions covered by the Emotiv EPOC it is possible to create pre-processed files with the values corresponding with the locations covered by the Emotiv EPOC: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4.

As shown in Table 3 the global accuracy stays over the chance success rate (33%). Also, when comparing motor vs non-motor patterns a higher variance is found between subjects, which was already shown in Table 1 for the Data Set V pre-processed data. However, it can still be seen that there are some categories which, for each user, are classified with a better accuracy: “R” for Subject 1 and “W” for Subjects 2 and 3.



**Table 4**  
BCI Competition III Data Set V Emotiv channels confusion matrix.

	Predicting Left	Predicting Right	Predicting Word
Subject 1			
Real Left	28	92	22
Real Right	1	131	8
Real Word	4	45	139
Subject 2			
Real Left	31	29	60
Real Right	15	74	71
Real Word	3	16	175
Subject 3			
Real Left	42	45	71
Real Right	37	53	72
Real Word	20	30	106

**Table 5**  
Accuracy levels achieved using the Emotiv EPOC recorded data shown as %.

Success Rate					
	Global	Motor	Right	Left	Word
Subject 4	69.04	82.22	41.61	72.63	92.00
Subject 5	63.50	82.51	49.43	93.79	50.00
Subject 6	55.29	80.35	47.40	53.10	66.90

Table 4 reveals the confusion matrix obtained when classifying Data Set V data using the positions available in the Emotiv headset. It is maintained that, for each subject, there are some confusion types which occur very rarely. Moreover, as it can be seen from Table 2, the Predicting Word task is the most successfully predicted across the users.

#### 4.3. Emotiv EPOC recorded data

The Emotiv EPOC sensor positions are shown in Fig. 2b.

As shown in Table 5, it is apparent that the classification success rate is higher than chance success rate (33%) in all scenarios. From this data, it is shown how the user with the greater previous experience (Subject 4) achieves better accuracy than the other two (Subject 5, Subject 6). However, the difference between the scores achieved is not so sharp as found on the BCI Competition data. Interestingly, there are no significant differences in the Motor success rate across subjects, showing a value maintained above 80% for all the Emotiv EPOC datasets. The same happens with the Right success rate, which differs from 41.61% to 49.42%. On the other hand, the Left success rate ranges from 53.10% until 93.79% and the Word success rates varies it from 50% to 92%.

No pattern can be established from the analysis of the last three columns apart from a higher discriminant level of a specific thought for each user: “W” for Subject 4 and Subject 6, “L” for Subject 5.

What can be seen from Table 6 is a high number of confusions due to a “R” pattern mistaken by a “L” pattern across all the subjects. In fact, a correlation between these confusions can be generalized as they happen more regularly when comparing Real “R” or “L” with predicting “W” or Real “W” with predicting “R” or “L”. In summary, when comparing motor vs. non-motor tasks. In contrast, there are some confusions which rarely appear as “W” being mistaken by “R” by Subject 4. Besides, it is interesting to note that “W” has also been most accurately predicted thought for Subjects 4 and 6, showing the highest value on their confusion matrixes.

## 5. Discussion

The present study was designed to assess the quality of the data captured by a low cost headset when using it in a system applied to

**Table 6**  
Emotiv data confusion matrix

	Predicting Left	Predicting Right	Predicting Word
Subject 4			
Real Left	130	25	24
Real Right	38	62	49
Real Word	8	4	138
Subject 5			
Real Left	136	2	7
Real Right	86	86	2
Real Word	56	16	72
Subject 6			
Real Left	77	47	21
Real Right	69	82	22
Real Word	37	11	97

**Table 7**  
BCI Competition Set V pre-processed data (BCI Comp – Pre) vs. BCI Competition Set V Emotiv channels (BCI Comp – Emo) success rate comparison.

	Global	Motor	Right	Left	Word
Subject 1					
BCI Comp – Pre	87.67	92.47	78.91	92.31	90.56
BCI Comp – Emo	63.40	83.19	93.57	19.72	73.94
Variation	<b>24.27</b>	<b>9.28</b>	<b>–14.66</b>	<b>72.59</b>	<b>16.62</b>
%	<b>27.68</b>	<b>10.04</b>	<b>–18.58</b>	<b>78.64</b>	<b>18.35</b>
Subject 2					
BCI Comp – Pre	82.26	88.02	81.25	77.78	85.71
BCI Comp – Emo	59.07	68.35	46.25	25.83	90.21
Variation	<b>23.19</b>	<b>19.67</b>	<b>35</b>	<b>51.95</b>	<b>–4.5</b>
%	<b>28.19</b>	<b>22.35</b>	<b>43.08</b>	<b>66.79</b>	<b>–5.25</b>
Subject 3					
BCI Comp – Pre	58.72	75.23	73.97	24.00	80.00
BCI Comp – Emo	42.23	59.45	32.72	26.58	67.95
Variation	<b>16.49</b>	<b>15.78</b>	<b>41.25</b>	<b>–2.58</b>	<b>12.05</b>
%	<b>28.08</b>	<b>20.98</b>	<b>55.77</b>	<b>–10.75</b>	<b>15.06</b>

a classic BCI problem. In this investigation, the output has been evaluated from the perspective of a final working application, including both the pre-processing and the classification stages. Therefore, there is not a comparison of the specific data quality of the Emotiv EPOC recorded data, but on the output accuracy of a BCI system using data from two different headsets. In this scenario a benchmark is required. For this reason, the guidelines of the “Data Set V: Multiclass Problem, Continuous EGG” proposed in the BCI Competition III contest have been chosen.

First, Table 7 provides a comparison of the results shown in Tables 3 and 1. As can be seen, there are number of important differences between the calculated success rates. Not only these become lower when using the Emotiv EPOC sensor positions, but the distribution of the success occurrences changes quite significantly. Moreover, the global success rate drops around 28% for all subjects. In contrast, the distribution of the changes causing the drop cannot be generalized.

Contradictory findings are found between subjects. For instance, there is a steep decrease between the Left success rates for Subjects 1 and 2 while the variation remains not quite significant for Subject 3. Also, Right success rate also shows a sharp reduction for Subjects 2 and 3 but improves by 18.58% Subject 1. What it is interesting in this data is the appearance of a much lower variation in the success rates of Motor and Word. Motor stays in the range from 10.04% to 22.35% variation (12.31) while Word is between 5.25% and 18.35% (13.1).

Previous results are confirmed in Table 8, which show the average success rate of the systems for the BCI Competition Set V subjects in the sample. It is apparent that a strong reduction of the Left success rate (62.84%) exists. However, the reduction on the Right success rate (26.31%) is on the same level as the overall decrease (Global – 27.97)

**Table 8**

BCI Competition Set V pre-processed data (BCI Comp – Pre) vs. BCI Competition Set V Emotiv channels (BCI Comp – Emo) success rate comparison. Average success rate.

Success Rate					
	Global	Motor	Right	Left	Word
BCI Comp – Pre	76.22	85.24	78.04	64.7	85.42
BCI Comp – Emo	54.9	70.33	57.51	24.04	77.37
Variation	<b>21.32</b>	<b>14.91</b>	<b>20.53</b>	<b>40.65</b>	<b>8.06</b>
%	<b>27.97</b>	<b>17.49</b>	<b>26.31</b>	<b>62.84</b>	<b>9.43</b>

**Table 9**

BCI Competition Set V Emotiv channels (Subjects 1, 2 and 3) vs. Emotiv EPOC data (Subjects 4–6) success rate comparison.

	Global	Motor	Right	Left	Word
Highest performers					
Subject 1 –	63.40	83.19	93.57	19.72	73.94
Subject 4 –	69.04	82.22	41.61	72.63	92.00
Variation	<b>–5.64</b>	<b>0.97</b>	<b>51.96</b>	<b>–52.91</b>	<b>–18.06</b>
%	<b>–8.9</b>	<b>1.17</b>	<b>55.53</b>	<b>–268.31</b>	<b>–24.43</b>
Medium performers					
Subject 2	59.07	68.35	46.25	25.83	90.21
Subject 5	63.50	82.51	49.43	93.79	50.00
Variation	<b>–4.43</b>	<b>–14.16</b>	<b>–3.18</b>	<b>–67.96</b>	<b>40.21</b>
%	<b>–7.5</b>	<b>–20.72</b>	<b>–6.88</b>	<b>–263.1</b>	<b>44.57</b>
Lowest performers					
Subject 3	42.23	59.45	32.72	26.58	67.95
Subject 6	55.29	80.35	47.40	53.10	66.90
Variation	<b>–13.06</b>	<b>–20.9</b>	<b>–14.68</b>	<b>–26.52</b>	<b>1.05</b>
%	<b>–30.93</b>	<b>–35.16</b>	<b>–44.87</b>	<b>–99.77</b>	<b>1.55</b>

and the Word status remains the more robust prediction with only a 9.43% loss of accuracy.

The data presented highlights the relevance of the sensor location on the overall system accuracy. As can be seen, most of the changes on the prediction of the system are related to the internal Motor tasks (Right vs. Left). When changing the positions used from the sensor cortex area of the brain (green sensors in Fig. 2a) to more lateral areas as represented by 2b the headset fails to record more accurately changes of mu and beta rhythms associated to motor imagery tasks. This reduces the system capacity to detect a decrease on them when the movement starts (event-related desynchronization (ERD)), and the increase of them after the movement and with relaxation (event-related synchronization (ERS) and occurs) (Wolpaw, Birbaumer, McFarland, Pfurtscheller, & Vaughan, 2002).

In contrast to the results for BCI Competition only data, Table 9 shows a system accuracy in a similar range for Highest (Subjects 1 and 4) and Medium (Subjects 2 and 5) performers, presenting an important variation only for the Lowest performers (Subjects 3 and 6). It is apparent from this table that the precision achieved by the S-dFasArt method for the Emotiv EPOC recorded datasets clearly outperform the results obtained for BCI Competition datasets for the EPOC sensor positions. The criteria to name the Subjects has been chosen to follow the same rules as on the BCI Competition, where the users were sorted from highest to lowest according to the success rate achieved, thus helping to compare the final results.

Interestingly, when analyzing in more detail the Motor tasks, it can be seen that the system accuracy is very similar for the Emotiv EPOC datasets whereas quite different for BCI Competition datasets (ranging from 59.45% to 83.19%). Comparing the results in more detail, higher precision for the Emotiv EPOC when predicting Left and BCI Competition when predicting Right can be found.

The most obvious finding to emerge from this study is that the overall performance of the BCI system when using channels on Emotiv headset positions is higher for the Emotiv EPOC than for the BCI Competition datasets. As Table 10 reveals, the average Emotiv EPOC

**Table 10**

BCI competition Set V Emotiv channels (Subjects 1, 2 and 3) vs. Emotiv EPOC data (Subjects 4–6) success rate comparison. Average success rate.

Success Rate					
	Global	Motor	Right	Left	Word
BCI Comp – Pre	54.9	70.33	57.51	24.04	77.37
Emotiv EPOC	62.61	81.69	46.15	73.17	69.63
Variation	<b>–7.71</b>	<b>–11.36</b>	<b>11.37</b>	<b>–49.13</b>	<b>7.73</b>
%	<b>–14.04</b>	<b>–16.16</b>	<b>19.76</b>	<b>–204.34</b>	<b>10</b>

BCI system accuracy is up to 14.04% higher than the BCI Competition V when the Emotiv EPOC positions are chosen. Likewise, a more evenly distribution of the success rate across predictions can be found for the Emotiv dataset (27.03 variance compared to 53.32).

Also, a trend of a better distinction between Predicting Word and the rest of the task has been apparent on all the confusion matrixes presented (Tables 2, 4 and 6), clearly showing how thoughts created in different brain areas facilitate the task of predicting a certain their appearance.

## 6. Conclusion

The presented paper has undertaken the application of a low cost consumer EEG headset to a well-known BCI problem. The focus has been set at the application level, considering the signal acquisition system as part of a global system including other features such as the signal processing or the classification modules. Therefore, this paper does not include a comparison of the quality of the signals recorded but the performance of the overall process when performing a defined mental task.

Also, a problem presented for the BCI Competition III, the Data Set V: Multiclass Problem, continuous EEG has been used as a baseline. This benchmark provides raw data of 32 channels and a subset of pre-processed data of 8 channels belonging to the motor cortex area of the brain. With the aim of providing with an accurate comparison between the low cost recorded data and these datasets, the same experiment conditions and data processing methodologies have been maintained for Emotiv EPOC recordings.

The results obtained seem to be in line with some of the authors included in the bibliography, who consider low cost EEG headsets as an interesting device for the development of BCI applications. Other areas of interest include the testing of pre-processing and classification methodologies, as any improvement achieved by using data recorded with consumer headsets will reasonably translate to medical systems, which are built using better components.

The evidence from this study suggests that the Emotiv EPOC low cost headset can be of interest for the development of motor imagery BCI applications. Because low cost devices can offer comparable results for certain applications it is expected a reduction of the cost of the EEG data recording systems, which should increase the research effort on the motor imagery problem. The authors foresee several areas where the findings on this paper can be significant.

Millions of people suffer of mobility impairments because of accidents and diseases (The Internet Stroke Center, 2015; World Health Organization, 2013). Therefore, there is a need for providing this population with systems which could help them to improve their daily lives. Controlling a wheel chair or a keyboard are classic examples appearing in the literature but the authors can foresee an important area of research linked to domotics. Simple actions like switching lights on and off, opening doors or systems capable of moving patients on and off the bed could make a difference in the life of these people, apart from any improvement on technologies which could make them independent to, for example, have a shower.

However, the results presented on this research paper still require further improvements if they are to be used in live BCI systems. The

first point to address is the performance level achieved. An average 62% accuracy, in spite of being in the range of the literature published for the motor imagery problem, may not be sufficient for certain applications and would cause frustration in the users. For instance, directing a wheel chair will require a higher success rate to make sure the path is right and the user can move and stop when required. Another constraint is the response time. The analysis being presented is based on off-line processing but the computing times should be shorter to improve online use. An obvious option is channel and feature selection, as the authors have already undertaken (Martinez-Leon et al., 2015).

Other research lines arise from this paper. The Emotiv EPOC does not provide with any sensor over the motor cortex area (C3 and C4 sensor positions), which is where the motor imagery intentions are best discriminated. Therefore, it would be required to repeat the same experiment with the sensors in different positions to find the sensor yielding the best discrimination between tasks. In line to that research, another line could be repeating this experiment using the EasyCap headset presented by Debener et al. (2012).

Once the low cost system can be considered fit for purpose, it would be necessary to review the ergonomics. Last, any finding would require a test over a larger population, and a generalization of the results.

The Emotiv recorded raw signal and pre-processed datasets are part of the contribution of this paper and have also been published for the research community to use.

## Acknowledgements

This research has been carried out in the framework of the project Associate - Decoding and stimulation of motor and sensory brain activity to support long term potentiation through Hebbian and paired associative stimulation during rehabilitation of gait (DPI2014-58431-C4-2-R), funded by the Spanish Ministry of Economy and Competitiveness and by the European Union through the European Regional Development Fund (ERDF) "A way to build Europe".

## Appendix A. Emotiv data pre-processing dataset

The paper describes the results achieved using the S-dFasArt classification algorithm proposed by Cano-Izquierdo et al. (2009), who are also authors of this paper. The pre-computed sets used by the methodology are the result of several transformations of the raw data, which are detailed below.

Also, some more detail is now given about the procedure followed to record and pre-process the data captured with Emotiv.

### Data gathering

The raw data was recorded from three right-handed healthy male subjects. Subject 4 achieved the highest success rate and had previous experience using the Emotiv EPOC and the Emotiv Control Panel, which is the tool Emotiv provides to gain experience with the headset. The other two lacked of any EEG experience or mental training.

The recordings were all completed after 6pm in a laboratory at the Technical University of Cartagena. Although no special magnetic isolation was available the experiment was carried out in a quiet environment where only the Subject and the operative setting up the headset were present. Also, because of the time the recordings were done, there were no external noise which could affect the quality of the captured data.

The users comfortably sat on a normal chair with relaxed arms resting on their legs a meter far from a computer screen which was displaying the images indicating the different statuses. Each user completed his recording during the same day, each lasting 4 min with

5–10 min breaks between them. As previously discussed, the experiment consisted on thinking about three mental statuses changing every 15 s:

1. Think about continuously moving the left hand (class 2, "L"). Represented by a left arrow.
2. Think about continuously moving the right hand (class 3, "R"). Represented by a right arrow.
3. Think about words starting with the same defined character (class 7, "W"). Represented by a frame showing a letter where an algorithm was developed to prevent the same letter to appear more than once for a given recording.

### Data pre-processing

First, the captured signals were spatially filtered by means of a full-resolution Surface Laplacian (SL). After that, the time varying spectrograms were computed by estimating the Power Spectral Density (PSD) using the Welch periodogram algorithm. Epochs were divided into segments of 1 s with a Hann window of the same length applied to each segment and 50% overlapping between them.

The frequency band chosen was between 8 and 30 Hz with a resolution of 2 Hz and the sampling frequency was 128 Hz. An additional advance rate of 8 samples between windows was defined, causing an overlapping of 93.75% between epochs.

A new value of the PSD is calculated with a frequency of 16 Hz. This way, during the available half second to make a prediction, 8 vectors per sensor are generated. Besides, each vector is formed by 168 elements, which is the result of multiplying the 12 frequency bands between 8 and 30 Hz using a bandwidth of 2 Hz, and 14 sensors.

### Dataset format

The dataset provided as part of this research paper includes 4 sessions of raw and preprocessed data files recorded from 3 users. This way, because two files are provided per session and per user, a total of 24 files are provided.

The raw data files contain:

1. Matrix *X* provides with the values of the potentials recorded from the scalp of the users by the 14 sensors of the Emotiv EPOC headset.
2. Vector *Y* contains the targets. As shown earlier on this paper thinking about continuously moving the left hand has a value of 2, thinking about continuously moving the right hand has a value of 3 and thinking about words starting with the same defined character has a value of 7.
3. *nfo* structure:
  - (a) *name* holds the name of the file
  - (b) *clab* displays the name of the sensors used on the recordings. The order of the sensors on this part of the structure define the order of the data available in Matrix *X*.
  - (c) *fs* is the sampling frequency.
  - (d) *xpos* holds the position *X* of the sensors included in *clab* according to the 10–20 international BCI positioning system.
  - (e) *ypos* holds the position *Y* of the sensors included in *clab* according to the 10–20 international BCI positioning system.

The pre-processed data files contain the converted files after applying an spatial Surface Laplacian filtering and a PSD preprocessing method. The researchers will find the following information when loading one of these files:

1. Matrix *X* provides with the values of the preprocessed data. It contains 168 values per row because the PSD calculation is performed with a bandwidth of 2 Hz between 8 and 30 Hz for each of the 14 channels of raw data recorded. This provided with 14 sensors by 12 different values of the PSD, which yields a result of 168 values.



2. Vector Y contains the targets. As shown earlier on this paper thinking about continuously moving the left hand has a value of 2, thinking about continuously moving the right hand has a value of 3 and thinking about words starting with the same defined character has a value of 7.
3. *nfo* structure:
  - (a) *name* holds the name of the file.
  - (b) *clab* displays the name of the sensors used on the recordings. The order of the sensors on this part of the structure define the order of the data available in Matrix X.
  - (c) *fs* is the sampling frequency.
  - (d) *xpos* holds the position X of the sensors included in *clab* according to the 10–20 international BCI positioning system.
  - (e) *ypos* holds the position Y of the sensors included in *clab* according to the 10–20 international BCI positioning system.

### Supplementary material

Supplementary material associated with this article can be found, in the online version, at [10.1016/j.eswa.2015.11.015](http://dx.doi.org/10.1016/j.eswa.2015.11.015)

### References

- Aler, R., Galván, I., & Valls, J. (2009). Transition detection for brain computer interface classification. In *Proceedings of biomedical engineering systems and technologies international joint conference: Biostec* (pp. 200–210). Porto, Portugal: Springer.
- Aler, R., Galván, I., & Valls, J. (2010). Evolving spatial and frequency selection filters for brain-computer interfaces. In *Proceedings of IEEE world congress in computational intelligence (WCCI) 2010* (pp. 1–7). Spain: Barcelona.
- Aler, R., Galván, I., & Valls, J. (2012). Applying evolution strategies to preprocessing EEG signals for brain-computer interfaces. *Information Sciences*, 215, 53–66.
- AlZubi, H., Al-Zubi, N., & Al-Nuaimy, W. (2011). Toward inexpensive and practical brain-computer interface. In *Proceedings of developments in e-systems engineering (DESE)* (pp. 98–101). IEEE.
- Badcock, N., Mousikou, P., Mahajan, Y., de Lissa, P., Thie, J., & McArthur, G. (2013). Validation of the Emotiv EPOC EEG gaming system for measuring research quality auditory ERPs. *PeerJ*, 1, e38.
- Biosemi (2015). Biosemi. <http://www.biosemi.com/faq/prices.htm>.
- Blankertz, B., Müller, K., Krusienski, D., Schalk, G., J. W., Schlögl, A., ... Birbaumer, N. (2006). The BCI competition III: validating alternative approaches to actual BCI problems. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(2), 153–159.
- Bobrov, P., Frolov, A., Cantor, C., Fedulova, I., Bakhnyan, M., & Zhavoronkov, A. (2011). Brain-computer interface based on generation of visual images. *PLoS One*, 6(6), e20674.
- Bueno, L., & Bastos-Filho, T. (2015). A self-organizing maps classifier structure for brain-computer interfaces. *Research on Biomedical Engineering*, 31(3), 232–240. doi:10.1590/2446-4740.0753.
- Cano-Izquierdo, J., Almonacid, M., Pinzolas, M., & Ibarrola, J. (2009). dFasArt: dynamic neural processing in FasArt model. *Neural Networks*, 22, 479–487.
- Cano-Izquierdo, J., Ibarrola, J., & Almonacid, M. (2012). Improving motor imagery classification with a new BCI design using neuro-fuzzy S-dFasArt. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20(1), 2–7.
- Cernea, D., Olech, P., Ebert, A., Kerren, A., Garth, C., Middel, A., & Hagen, H. (2011). Controlling in-vehicle systems with a commercial eeg headset: performance and cognitive load. In *Proceedings of IRTG 1131 workshop on visualization of large and unstructured data sets: applications in geospatial planning, modeling and engineering: vol. 27* (pp. 113–122). Schloss Dagstuhl-Leibniz-Zentrum fuer Informatik.
- Clemente, M., Rodriguez, A., Rey, B., & Alcañiz, M. (2014). Assessment of the influence of navigation control and screen size on the sense of presence in virtual reality using EEG. *Expert Systems with Applications*, 41, 1584–1592.
- De-Vos, M., Gandras, K., & Debener, S. (2013). Towards a truly mobile auditory brain-computer interface: exploring the P300 to take away. *International Journal of Psychophysiology*, 91, 46–53.
- Debener, S., Minow, F., Emkes, R., Gandras, K., & Vos, M. (2012). How about taking a low-cost, small, and wireless EEG for a walk? *Psychophysiology*, 49, 1449–1453.
- Dkhil, M., Neji, M., Wali, A., & Alimi, A. (2015). A new approach for a safe car assistance system. In *Proceedings of the 14th IEEE international conference on advanced logistics and transport (ICAL T), Valenciennes, France* (pp. 217–222).
- Duvinage, M., Castermans, T., Petieau, M., Hoellinger, T., Cheron, G., & Dutoit, G. (2013). Performance of the Emotiv eeg headset for p300-based applications. *BioMedical Engineering Online*, 12(56), 1:15.
- Emotiv (2015). Emotiv. <http://www.emotiv.com/>.
- Esfahani, E., & Sundararajan, V. (2011). Using brain-computer interfaces to detect human satisfaction in human-robot interaction. *International Journal of Humanoid Robotics*, 8(01), 87–101.
- Fok, S., Schwartz, R., Wronkiewicz, M., Holmes, C., Zhang, J., Somers, T., ... Leuthardt, E. (2011). An EEG-based brain computer interface for rehabilitation and restoration of hand control following stroke using ipsilateral cortical physiology. In *Proceedings of the 33 annual international conference of the IEEE on engineering in medicine and biology society, EMBC, Boston, USA* (pp. 6277–6280).
- Galán, F., Oliva, F., & Guardia, J. (2007). Using mental tasks transitions detection to improve spontaneous mental activity classification. *Medical Biological Engineering Computation*, 45, 603–609.
- Ghosh, P., Mazumder, A., Bhattacharyya, S., Tibarewala, D., & Hayashibe, M. (2015). Functional connectivity analysis of motor imagery EEG signal for brain-computer interfacing application. In *Proceedings of the 7th annual international IEEE EMBS conference on neural engineering, Montpellier, France* (pp. 210–213).
- Gómez-Gil, J., San-José-González, I., Nicolás-Alonso, L., & Alonso-García, S. (2011). Steering a tractor by means of an EMG-based human-machine interface. *Sensors*, 11, 7110–7126.
- Khushaba, R. N., Greenacre, L., Kodagoda, S., Louviere, J., Burke, S., & Dissanayake, G. (2012). Choice modeling and the brain: a study on the electroencephalogram (EEG) of preferences. *Expert Systems with Applications*, 39, 12378–12388.
- Khushaba, R. N., Wise, C., Kodagoda, S., Louviere, J., Kahn, B., & Townsend, C. (2013). Consumer neuroscience: assessing the brain response to marketing stimuli using electroencephalogram (EEG) and eye tracking. *Expert Systems with Applications*, 40(9), 3803–3812.
- Kumari, P., & Vaish, A. (2015). Brainwave based user identification system: a pilot study in robotics environment. *Robotics and Autonomous Systems*, 65, 15–23.
- Van-de Laar, B., Gurkok, H., Plass-Oude Bos, D., Poel, M., & Nijholt, A. (2013). Experiencing BCI control in a popular computer game. *IEEE Transactions on Computational Intelligence and AI in Games*, 5(2), 176–184.
- Lievesley, R., Wozencroft, M., & Ewins, D. (2011). The emotiv eeg neuroheadset: an inexpensive method of controlling assistive technologies using facial expressions and thoughts? *Journal of Assistive Technologies*, 5(2), 67–82.
- Lin, C., & Hsieh, M. (2009). Classification of mental task from EEG data using neural networks based on particle swarm optimization. *Neurocomputing*, 72, 1121–1130.
- Martinez-Leon, J., Cano-Izquierdo, J., & Ibarrola, J. (2015). Feature selection applying statistical and neurofuzzy methods to EEG-based BCI. *Computational Intelligence and Neuroscience*, 2015, 1–17.
- McFarland, D., McCane, L., David, S., & Wolpaw, J. (1997). Spatial filter selection of EEG-based communication. *Electroencephalography and Clinical Neurophysiology*, 103(3), 386–394.
- McMahan, T., Parberry, I., & Parsons, T. (2015). Modality specific assessment of video game player's experience using the Emotiv. *Entertainment Computing*, 7, 1–6.
- Millan, J., & Carmenta, J. (2010). Invasive or noninvasive: understanding brain-machine interface technology. *IEEE Engineering in Medicine and Biology Magazine*, 29, 16–22.
- Moon, S., Bawane, N., & Hazare, P. (2015). Selection of optimum features for neural network using genetic algorithm in classification of brain computer interface data. *International Journal of Advanced Research in Computer and Communication Engineering*, 4(7), 426–428.
- Neurosky (2015). Neurosky. <http://neurosky.com/biosensors/eeg-sensor/>.
- Stopczynski, A., Stahlhut, C., Petersen, M. K., Larsen, J., Jensen, C., Ivanova, M., ... Hansen, L. (2013). Smartphones as pocketable labs: visions for mobile brain imaging and neurofeedback. *International Journal of Psychophysiology*, 91, 54–66.
- Sun, S., & Zhang, C. (2006). Adaptive feature extraction for EEG signal classification. *Medical and Biological Engineering and Computing*, 44(10), 931–935.
- Sun, S., Zhang, C., & Lu, Y. (2008). The random electrode selection ensemble for EEG signal classification. *Pattern Recognition*, 41(5), 1663–1675.
- Tangermann, M., Müller, K., Aertsen, A., Birbaumer, N., Braun, C., Brunner, C., ... Müller-Putz, G., et al. (2012). Review of the BCI competition IV. *Frontiers in Neuroscience*, 6, 1–31.
- Taylor, G., & Schmidt, C. (2012). Empirical evaluation of the Emotiv EPOC BCI headset for the detection of mental actions. In *Proceedings of the human factors and ergonomics society annual meeting 2012, Boston, USA: vol. 56* (pp. 193–197).
- The Internet Stroke Center (2015). Stroke statistics. <http://www.strokecenter.org/patients/about-stroke/stroke-statistics/>
- Úbeda, A., Iáñez, E., Azorín, J. M., Sabater, J. M., & Fernández, E. (2013). Classification method for BCIs based on the correlation of EEG maps. *Neurocomputing*, 114, 98–106.
- Van-Vliet, M., Robben, A., Chumerin, N., Manyakov, N., Combaz, A., & Van-Hulle, M. (2012). Designing a brain-computer interface controlled video-game using consumer grade EEG hardware. In *Proceedings of biosignals and biorobotics conference (BRC) on intelligent sensors, sensor networks and information processing, ISSNIP* (pp. 1–6). IEEE.
- Vourvopoulos, A., Liarakis, F., & Petridis, P. (2012). Brain-controlled serious games for cultural heritage. In *Proceedings of the 18th international conference on virtual systems and multimedia (VSMM 2012)* (pp. 291–298). IEEE.
- Wolpaw, J., Birbaumer, N., McFarland, D., Pfurtscheller, G., & Vaughan, T. (2002). Brain-computer interfaces for communication and control. *Clinical neurophysiology*, 113(6), 767–791.
- World Health Organization (2013). Spinal cord injury: as many as 500,000 people suffer each year. <http://www.who.int/mediacentre/news/releases/2013/spinal-cord-injury-20131202/en/>